



Inês Menino Teixeira

Licenciada em Ciências de Engenharia e Gestão Industrial

Um modelo de previsão de preços spot de eletricidade através de redes neuronais artificiais

Dissertação para obtenção do Grau de Mestre em
Engenharia e Gestão Industrial

Orientadora: Professora Ana Paula Ferreira Barroso, Professora Auxiliar,
Faculdade de Ciências e Tecnologia da Universidade Nova de
Lisboa

Júri:

Presidente: Doutora Ana Sofia Leonardo Vilela de Matos,
Professora Associada da Faculdade de Ciências e
Tecnologia da Universidade NOVA de Lisboa

Arguente: Doutora Carla Maria Moreira Machado, Professora
Auxiliar da Faculdade de Ciências e Tecnologia
da Universidade NOVA de Lisboa

Vogais: Engenheira Teresa Marques, Vice-Diretora do
Planeamento Integrado da Produção e Energia da
Bondalti

Doutora Ana Paula Ferreira Barroso, Professora
Auxiliar da Faculdade de Ciências e Tecnologia
da Universidade NOVA de Lisboa



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE NOVA DE LISBOA

Junho, 2021

Um modelo de previsão de preços spot de eletricidade através de redes neuronais artificiais

Copyright © Inês Menino Teixeira, Faculdade de Ciências e Tecnologia, Universidade Nova de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade Nova de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

Agradecimentos

Agradeço ao Engenheiro João de Mello e à Bondalti pela oportunidade de estágio e a todos os seus colaboradores pela simpatia com que me receberam na empresa, especialmente, ao Engenheiro António Mesquita de Sousa, à Engenheira Teresa Marques e à Engenheira Catarina Matos pela disponibilidade, pela partilha de conhecimentos e por todo o apoio prestado no desenvolvimento deste trabalho.

Agradeço à Professora Ana Paula Barroso pela disponibilidade, orientação e supervisão da presente dissertação.

Por fim, agradeço aos meus pais, irmão e restantes familiares e amigos, em especial ao Mário Mendes, pelo apoio durante todo o meu percurso académico.

Resumo

Com o desenvolvimento do mercado liberalizado de eletricidade, os intervenientes neste mercado sentem cada vez mais a necessidade de definir estratégias de compra e venda de eletricidade. Tendo em conta as várias opções de compra e venda, as previsões de preços de eletricidade tornaram-se uma importante ferramenta para todos os intervenientes deste mercado, desde os produtores aos consumidores, para determinar os contratos de compra/venda com os melhores preços.

Esta dissertação visa contribuir para a melhoria do processo de tomada de decisão de compra de eletricidade. O objetivo é desenvolver um modelo de previsão de preços *spot* de eletricidade com base nos preços de eletricidade definidos nos mercados a prazo (preços futuros). Composto por redes neuronais artificiais treinadas com o algoritmo *Extreme Learning Machine*, o modelo utiliza o histórico de preços *spot* e preços futuros mensais e trimestrais para determinar a média mensal do preço *spot* dos próximos 6 meses.

O modelo desenvolvido foi aplicado em dois cenários, pré-pandemia e pandemia, e avaliado com base na raiz quadrática do erro quadrático médio. Em ambos os cenários, os resultados obtidos mostram que a raiz quadrática do erro quadrático médio é frequentemente inferior ao módulo da diferença entre preços futuros e preços *spot* para o mesmo período de entrega, mostrando que a sua aplicação pode contribuir para a melhoria do processo de tomada de decisão de compra nos mercados de futuros mensais do Mercado Ibérico de Eletricidade e, consequentemente, para a redução da fatura energética.

Palavras-chave: Mercado de eletricidade, Previsão de preços *spot*, Redes Neuronais Artificiais, *Extreme Learning Machine*

Abstract

With the development of the deregulated electricity market, the participants in this market increasingly feel the need to define electricity trading strategies. Considering all trading options, electricity price forecasts became an important tool for every market participant, from producers to consumers, which aims to determine the buy/sell contracts with the best price.

This dissertation aims to contribute to the improvement of the decision-making process for the purchase of electricity. The purpose is to develop an electricity spot price forecast model based on the prices established on the future markets (future prices). Composed by artificial neural networks trained with the Extreme Learning Machine algorithm, this model uses historical data of the spot prices and monthly and quarter future prices since 2016 to determine the monthly average spot price for the next six months.

The model developed was applied in two scenarios, pre-pandemic and pandemic, and evaluated through the Root Mean Square Error. In both scenarios, the results prove that the Root Mean Square Error is usually lower than the module of the difference between future prices and spot prices for the same delivery period, showing that its application can contribute to the improvement of the decision-making process for the purchase of electricity in the monthly futures of the Iberian Electricity Market and, consequently, to reduce energy bills.

Keywords: Electricity Market, Spot Prices Forecast, Artificial Neural Network, Extreme Learning Machine

Índice

1.	Introdução	1
1.1.	Enquadramento	1
1.2.	Motivação	1
1.3.	Objetivo.....	2
1.4.	Metodologia utilizada.....	2
1.5.	Estrutura da dissertação.....	3
2.	Mercado da eletricidade.....	5
2.1.	Sistema Elétrico Nacional.....	5
2.1.1.	Produção	5
2.1.2.	Transporte e distribuição	6
2.1.3.	Comercialização	7
2.1.4.	Faturas de eletricidade. Composição	13
2.2.	Preços <i>spot</i> e preços futuros.....	13
2.3.	Variáveis influentes nos preços de eletricidade	15
2.3.1.	Formação de preços grossistas	15
2.3.2.	Fatores socioeconómicos	18
2.4.	Medidas de correlação	20
2.5.	Modelos de previsão de preços <i>spot</i> de eletricidade	20
2.5.1.	Modelos multi-agente	22
2.5.2.	Modelos fundamentais	22
2.5.3.	Modelos estocásticos	23
2.5.4.	Modelos estatísticos	25
2.5.5.	Modelos computacionais	26
2.6.	Modelo de Redes Neurais Artificiais treinadas com o algoritmo ELM	28
2.7.	Síntese do capítulo.....	30
3.	Estudo de caso e análises preliminares	33
3.1.	Enquadramento	33
3.2.	Medidas adotadas para reduzir o consumo de eletricidade.....	34
3.3.	Estratégias de compra de eletricidade	34
3.4.	Modelo de apoio à decisão de aquisição de eletricidade.....	35
3.5.	Preços <i>spot</i> de eletricidade	36
3.6.	Análise de variáveis influentes no preço <i>spot</i>	39
3.6.1.	Consumo	40
3.6.2.	Produção	42
3.7.	Seleção do modelo	49
3.8.	Síntese do capítulo	50

4.	Modelo de previsão de preços <i>spot</i> de eletricidade	51
4.1.	Modelo de previsão de preços <i>spot</i> através de redes neurais artificiais	51
4.2.	Avaliação do modelo de previsão	54
4.3.	Aplicação do modelo ao estudo de caso	54
4.3.1.	Etapa 1. Recolha e tratamento de dados	54
4.3.2.	Etapa 2. Desenvolvimento do algoritmo	55
4.3.3.	Etapa 3. Definição dos períodos de treino e de teste	56
4.3.4.	Etapa 4. Otimização dos parâmetros do modelo	56
4.3.5.	Etapa 5. Determinação da previsão dos preços <i>spot</i>	61
4.3.6.	Etapa 6. Determinação dos preços de referência em função do risco de compra no mercado diário	62
4.4.	Impacto das variáveis influentes no preço <i>spot</i>	64
4.5.	Síntese do capítulo	66
5.	Conclusões	69
5.1.	Resultados	69
5.2.	Limitações	67
5.3.	Trabalhos futuros	68
	Bibliografia	69
	Anexos	75
	ANEXO I. Média mensal dos preços <i>spot</i> reais, média mensal dos preços <i>spot</i> estimados e preços futuros na fase de teste. Cenário pré-pandemia	75
	ANEXO II. Média mensal dos preços <i>spot</i> reais, média mensal dos preços <i>spot</i> estimados e preços futuros na fase de teste. Cenário pandemia	77

Índice de figuras

Figura 2.1: Repartição do consumo no mercado liberalizado e no mercado regulado em Portugal de 2013 a 2017	7
Figura 2.2: Principais mercados e os respetivos períodos de negociações.....	8
Figura 2.3: Curva da oferta de energia elétrica para o mercado português na hora 17 do dia 23 de outubro de 2007.	9
Figura 2.4: Formação do preço marginal de mercado.....	9
Figura 2.5: Horários por sessão de negociações do mercado intradiário	10
Figura 2.6: Contratos a prazo em 9 de outubro de 2018.....	13
Figura 2.7: Média mensal do preço <i>spot</i> e preço de futuros mensais $M + 1$	14
Figura 2.8: Variáveis que determinam o preço marginal de mercado do MIBEL e disponibilidade destes dados	17
Figura 2.9: Dispersão das variáveis X e Y com diferentes coeficientes de Pearson	20
Figura 2.10: Modelos utilizados para a previsão de preços de eletricidade	21
Figura 2.11: Relação entre o preço e o consumo de eletricidade no mercado nórdico.	23
Figura 2.12: Estrutura de um modelo híbrido com decomposição da série	24
Figura 2.13: Estrutura de uma RNA.....	27
Figura 2.14: Estrutura de uma RNA treinada com o algoritmo ELM.	29
Figura 3.1: Preços <i>spot</i> em Espanha e em Portugal em março de 2019.....	36
Figura 3.2: Média mensal e variância do preço <i>spot</i> entre janeiro de 2016 e dezembro de 2020	37
Figura 3.3: Fatores sazonais semanais	37
Figura 3.4: Fatores sazonais mensais	38
Figura 3.5: Fatores sazonais anuais.....	39
Figura 3.6: Média mensal do consumo de eletricidade na Península Ibérica de 1 de janeiro de 2016 a 31 de dezembro de 2019	40
Figura 3.7: Consumo de eletricidade na Península Ibérica e temperatura atmosférica em Madrid de 1 de janeiro de 2016 a 31 de dezembro de 2019	41
Figura 3.8: Consumo de eletricidade na Península Ibérica em 2019.....	41
Figura 3.9: Consumo médio de eletricidade na Península Ibérica e preço <i>spot</i> por dia da semana de 1 de janeiro de 2016 a 31 de dezembro de 2019.....	41
Figura 3.10: Média do consumo de eletricidade na Península Ibérica nos últimos sete dias e média do preço <i>spot</i> nos últimos sete dias ao longo do primeiro trimestre de 2019	42
Figura 3.11: Evolução de cada tipo de produção entre 2016 e 2020 e mix de produção resultante dos 5 anos.....	43
Figura 3.12: Matriz de correlações	43
Figura 3.13: Relação entre o preço <i>spot</i> e a produção hídrica	44
Figura 3.14: Evolução do preço <i>spot</i> de eletricidade e preço do gás natural de 1 de janeiro de 2016 a 31 de outubro de 2020.....	44
Figura 3.15: Evolução das tecnologias marginais em Portugal e percentagem de ocorrências da tecnologia marginal em cada grupo de 2016 a 2020	45

Figura 3.16: Número de ocorrências em que cada tipo de produção foi tecnologia marginal por hora e média horária do consumo entre 1 de janeiro de 2016 e 31 de dezembro de 2020.....	45
Figura 3.17: Média do preço marginal de mercado em função da tecnologia marginal por ano	46
Figura 3.18: Média do preço marginal de mercado em função da tecnologia marginal por hora	47
Figura 3.19: Potência instalada na Península Ibérica de 2016 a 2020	47
Figura 3.20: Potência instalada na Península Ibérica por tipo de produção em 2018 e 2020.....	48
Figura 4.1: Estrutura da RNA para a previsão dos preços do mês M+1	52
Figura 4.2: Estrutura do modelo de previsão desenvolvido	52
Figura 4.3: Preço <i>spot</i> com e sem outliers de 21 de janeiro de 2017 a 14 de fevereiro de 2017	55
Figura 4.4: Preço <i>spot</i> entre 1 de janeiro de 2016 e 31 de dezembro de 2020, valor médio e data do início do período de treino para as hipóteses H1 e H2	56
Figura 4.5: RMSE usando a função de ativação tangente hiperbólica para a previsão do preço <i>spot</i> do mês M+1	57
Figura 4.6: RMSE usando a função de ativação sigmoide para a previsão do preço <i>spot</i> do mês M+1	57
Figura 4.7: Média mensal dos preços <i>spot</i> reais, média mensal dos preços <i>spot</i> estimados da RNA M+1 e preços futuros M+1 (cenário pré-pandemia)	58
Figura 4.8: Média mensal dos preços <i>spot</i> reais, média mensal dos preços <i>spot</i> estimados da RNA M+6 e preços futuros M+6 (cenário pré-pandemia)	58
Figura 4.9: Média mensal dos preços <i>spot</i> reais, média mensal dos preços <i>spot</i> estimados da RNA M+1 e preços futuros M+1 (cenário de pandemia).....	59
Figura 4.10: Média mensal dos preços <i>spot</i> reais, média mensal dos preços <i>spot</i> estimados da RNA M+6 e preços futuros M+6 (cenário de pandemia).....	59
Figura 4.11: Previsão da média mensal do preço <i>spot</i> para o primeiro semestre de 2021	61
Figura 4.12: Preços <i>spot</i> estimados e preço futuro para maio de 2021 (com base nos dados históricos até dia 20 de dezembro de 2020)	62
Figura 4.13: Preços de referência em função do risco de compra no mercado diário	63
Figura 4.14: Precisão das previsões do preço <i>spot</i> para o mês M+1	64
Figura 4.15: Precisão para previsões do preço <i>spot</i> para o mês M+6	65

Índice de tabelas

Tabela 2.1: Preços do mercado de futuros mensais em Portugal no dia 29 de outubro de 2020.....	13
Tabela 2.2: Tipos de modelos de previsão de preços <i>spot</i>	31
Tabela 3.1: Relação entre o preço <i>spot</i> e o produto do preço marginal por tecnologia marginal e da probabilidade de esse tipo de produção ser tecnologia marginal.....	47
Tabela 3.2: Estatísticas do preço <i>spot</i> e das variáveis influentes no preço <i>spot</i>	48
Tabela 3.3: Modelos aplicados à previsão de preços <i>spot</i> do MIBEL	49
Tabela 3.4: Variáveis com maior impacto nas ofertas de venda de eletricidade.....	50
Tabela 4.1: NCN's ótimos por função de ativação e RNA e respetivos RMSE's.....	57
Tabela 4.2: Parâmetros ótimos de cada RNA.....	57
Tabela 4.3: RMSE's e erros médios da previsão do preço <i>spot</i> do modelo e dos preços futuros obtidos na fase de teste	60
Tabela 4.4: Percentagem das decisões de compra ao melhor preço.....	61
Tabela 4.5: Preços futuros, preços <i>spot</i> previstos e preços de referência para o primeiro semestre de 2021	64

Lista de abreviaturas

AR	Autorregressão
ARIMA	<i>Autorregressive and Integrated Moving Average</i>
ARMAX	<i>Autorregressive and Moving Average with exogenous variables</i>
ARX	<i>Autorregressive with exogenous variables</i>
AT	Alta Tensão
BT	Baixa Tensão
CUR	Comercializador de Último Recurso
DGEG	Direção-Geral de Energia e Geologia
ELM	<i>Extreme Learning Machine</i>
ERSE	Entidade Reguladora dos Serviços Energéticos
GGs	Gestão Global do Sistema
GPL	Gás de Petróleo Liquefeito
GW	Gigawatt
GWh	Gigawatt hora
IEA	International Energy Agency
kW	Quilowatt
LSSVM	<i>Least Square Support Vector Machine</i>
LSTM	<i>Long-Short Term Memory</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MAT	Muito Alta Tensão
MIBEL	Mercado Ibérico de Eletricidade
MIBGÁS	<i>Mercado Ibérico del Gas</i>
MT	Média Tensão
MVS	Máquinas de Vetores de Suporte
MW	Megawatt
MWh	Megawatt hora
NCN	Número de Células Neuronais
OMIE	Operador de Mercado Ibérico (polo espanhol)
OMIP	Operador do Mercado Ibérico (polo português)
PRE	Produção/Produtores em Regime Especial
PRO	Produção/Produtores em Regime Ordinário
REE	<i>Red Eléctrica de España</i>
REN	Redes Energéticas Nacionais

RMSE	<i>Root Mean Square Error</i>
RNA	Redes Neurais Artificiais
RNR	Redes Neurais Recorrentes
SEN	Sistema Elétrico Nacional
sig	Função sigmoide
tanh	Função tangente hiperbólica
TTVCF	Tarifa Transitória de Venda ao Cliente Final

1. Introdução

O presente capítulo faz o enquadramento do problema e identifica a motivação, o objetivo e a metodologia utilizada.

1.1. Enquadramento

Atualmente, a eletricidade é normalmente transacionada em mercados grossistas liberalizados, tal como outras matérias-primas. O que distingue este produto das matérias-primas é a condição necessária de equilíbrio entre o consumo e a produção em todos os momentos e as diferenças entre as condições de produção associadas a cada tecnologia utilizada nesta atividade (Monteiro et al., 2020).

Na produção de eletricidade são utilizadas diversas fontes de energia, renováveis e não-renováveis, associadas a diferentes condições de produção. De um modo geral, a produção por fontes renováveis depende de determinadas condições atmosféricas e a produção por fontes não-renováveis depende dos preços dos combustíveis e dos preços de licenças de emissões de carbono emitidas durante a produção. O número de variáveis associadas à produção de eletricidade provoca uma enorme volatilidade nos preços de eletricidade.

Na Península Ibérica, o mercado organizado é assegurado pelo Mercado Ibérico de Eletricidade (MIBEL). O MIBEL é um mercado liberalizado em que os agentes de mercado podem optar por comprar eletricidade em mercados a curto, médio e longo prazos. O mercado a curto prazo inclui o mercado diário e os mercados de ajustes de última hora, que permitem reestabelecer o equilíbrio das curvas de oferta e de procura de eletricidade. O mercado a longo prazo é composto pelos mercados de futuros, cujo período de entrega de eletricidade pode ser semanal, mensal, trimestral e anual.

Com a evolução do mercado no sentido da liberalização, os agentes de mercado sentem cada vez mais a necessidade de implementar métodos de apoio à decisão relativamente às ofertas de compra ou venda que submetem em cada mercado, especialmente no que diz respeito às decisões de compra no mercado diário e no mercado de futuros. As previsões de preços de eletricidade tornaram-se assim, uma ferramenta essencial para as empresas da área da energia (Weron, 2007).

1.2. Motivação

O mercado da eletricidade tem evoluído de forma a dar aos consumidores intensivos de eletricidade mais poder para participar ativamente no mercado liberalizado, o que lhes permite definir e acordar as condições de negociação de energia com a comercializadora que lhe oferecer as melhores condições.

A enorme volatilidade associada aos preços de eletricidade no mercado também contribui para a importância da gestão dos contratos de aquisição de energia por parte dos consumidores industriais. Logo, os consumidores intensivos de energia sentem cada vez mais a necessidade de otimizar os recursos energéticos e desenvolver estratégias de negociações para obter energia elétrica ao melhor preço.

A Bondalti é uma empresa da indústria química que produz, nas suas instalações fabris, produtos químicos inorgânicos de base, cloro e seus derivados, e produtos químicos orgânicos de base (anilina e seus derivados). No caso do negócio de cloro e derivados, a eletricidade representa a maior parcela dos custos variáveis de produção, pelo que a empresa define medidas de redução de custos energéticos e estratégias de aquisição de eletricidade. Para reduzir a fatura energética, a Bondalti define estrategicamente quais os momentos em que deve negociar, procurando as soluções que oferecem os preços mais competitivos. Assim, a previsão de preços *spot* é uma ferramenta importante para a gestão de aquisição de eletricidade.

Atualmente, os principais mercados de eletricidade são os mercados de futuros e o mercado diário, onde são formados os preços *spot*. Devido à volatilidade dos preços de eletricidade, a escolha do mercado para adquirir energia pode afetar a fatura de eletricidade.

O mercado diário geralmente dispõe de preços mais baixos relativamente ao mercado de futuros. No entanto, devido à volatilidade dos preços *spot* (mercado diário), muitos compradores optam por adquirir a maioria da quantidade de eletricidade necessária nos mercados de futuros, sendo a restante eletricidade adquirida nos mercados a curto prazo.

A estimativa de preços *spot* permite estabelecer uma análise comparativa entre os preços futuros atuais e os preços *spot* para o mesmo período de entrega. Assim, a previsão de preços *spot* é uma ferramenta de auxílio ao processo de tomada de decisão no que diz respeito à aquisição de eletricidade no mercado de futuros.

1.3. Objetivo

O objetivo desta dissertação é desenvolver um modelo de previsão de preços *spot* para um horizonte de médio prazo com um erro associado inferior ao valor médio absoluto do *risk premium*, isto é, inferior à distância entre a média dos preços *spot* e os preços futuros para o mesmo período de entrega. Este modelo permite prestar auxílio no processo de tomada de decisão no que diz respeito à aquisição de eletricidade nos mercados futuros mensais.

1.4. Metodologia utilizada

A metodologia utilizada neste trabalho foi a seguinte:

1. Estudo do funcionamento do MIBEL e das estratégias de compra de eletricidade;
2. Definição do objetivo do modelo de previsão de preços *spot* de eletricidade e do horizonte temporal da previsão;
3. Pesquisa sobre as principais variáveis influentes no preço *spot* de eletricidade do MIBEL e disponibilidade dos dados destas variáveis;
4. Recolha de dados;
5. Análise da série de preços *spot* e das principais variáveis influentes no preço *spot*;
6. Estudo sobre os principais modelos para a previsão de preços *spot* de eletricidade;
7. Seleção do modelo de previsão;
8. Desenvolvimento do modelo de previsão no *software* Octave;
9. Validação do modelo (análise do erro);

10. Desenvolvimento de uma ferramenta para a análise de risco; e
11. Apresentação da previsão e da análise de risco.

1.5. Estrutura da dissertação

A dissertação está organizada em cinco capítulos.

O capítulo 1 faz o enquadramento do problema e identifica a motivação, o objetivo e a metodologia utilizada.

O capítulo 2 descreve o funcionamento do mercado de eletricidade, as variáveis influentes no preço *spot*, os estudos de casos aplicados com o objetivo de prever preços *spot* de eletricidade e o modelo de referência.

O capítulo 3 apresenta o estudo de caso, isto é, as diferentes estratégias de aquisição de eletricidade disponíveis para consumidores como a Bondalti, a análise das séries do preço *spot* e das variáveis influentes no preço *spot* e o processo para seleção do modelo de previsão.

O capítulo 4 apresenta a estrutura e o processo de desenvolvimento do algoritmo que está subjacente ao modelo, a previsão de preços *spot* e a análise de risco de compra no mercado de futuros.

O capítulo 5 apresenta as conclusões, as limitações do modelo desenvolvido e trabalho futuro.

2. Mercado da eletricidade

O presente capítulo descreve o funcionamento do mercado de eletricidade, as variáveis influentes no preço *spot*, os estudos de casos aplicados com o objetivo de prever preços *spot* de eletricidade e o modelo de referência.

2.1. Sistema Elétrico Nacional

O Sistema Elétrico Nacional (SEN) é um sistema complexo regulado pela Entidade Reguladora dos Serviços Energéticos (ERSE) e composto por diversos agentes em cada uma das suas atividades. São quatro as atividades do SEN, nomeadamente:

- Produção;
- Transporte;
- Distribuição; e
- Comercialização.

Em qualquer sistema elétrico atual, onde ainda não estão disponíveis soluções de armazenamento de eletricidade de grande escala, as quantidades de eletricidade produzida e consumida têm de ser iguais em todos os momentos para não ocorrerem falhas na rede. Assim, uma das principais preocupações da entidade reguladora e dos agentes nos ramos de transporte e distribuição é a garantia da continuidade de fornecimento da energia elétrica, que só pode ser estabelecida equilibrando as curvas da oferta e da procura. Em Portugal, a Redes Energéticas Nacionais (REN) é responsável pela gestão técnica global do sistema elétrico, que visa o funcionamento integrado e eficiente do SEN.

2.1.1. Produção

O mercado de eletricidade abrange vários tipos de produção consoante a fonte de energia utilizada, que pode ser renovável (hídrica, solar, eólica e biomassa), não-renovável (carvão, gás natural, fuelóleo e diesel). Existe ainda a produção a partir de energia nuclear, que apesar de utilizar uma fonte não-renovável, pode ser considerada uma energia limpa por não emitir gases com efeito de estufa.

Na produção hídrica, as unidades produtoras podem ser centrais de albufeira ou centrais a fio-de-água, sendo que as primeiras têm capacidade de armazenamento de água e as segundas são um aproveitamento, em tempo real, da energia gerada pelo caudal de um rio.

A produção de eletricidade a partir de energia térmica pode utilizar fontes renováveis (caso seja usada biomassa) ou não-renováveis. Os tipos de produção de eletricidade a partir de energia térmica são:

- **Produção térmica convencional** – Quando o calor produzido com a queima de um combustível é utilizado para gerar vapor de água, que, por sua vez, faz movimentar as pás das turbinas a vapor, convertendo cerca de 35% da energia do combustível em eletricidade (Galp Power, 2006);
- **Produção por cogeração** – Quando se utiliza o princípio da produção térmica e parte da energia gerada nas caldeiras que não é aproveitada para produzir eletricidade é aproveitada para

outros fins, proporcionando o aproveitamento de mais de 70% da energia proveniente dos combustíveis (fósseis ou biomassa) utilizados nesse processo;¹ e

- **Produção por ciclo combinado** – Quando a eletricidade é produzida através de turbinas a vapor (tal como acontece na produção térmica convencional) e de turbinas a gás, convertendo cerca de 55% a 60% da energia do combustível em eletricidade (Galp Power, 2006).

A produção de eletricidade a partir de energia solar pode ser térmica ou fotovoltaica. A produção via painéis fotovoltaicos converte diretamente energia solar em energia elétrica. A energia solar térmica converte a energia solar em calor, que pode ser utilizado, por exemplo, para o aquecimento da água. A produção de eletricidade via painéis solares térmicos recorre a um gerador, sendo necessário um maior número de transformações de energia até ao resultado final.²

O SEN distingue dois regimes de produção, aos quais atribui regulações distintas: a Produção em Regime Ordinário (PRO) e a Produção em Regime Especial (PRE). A PRE, sujeita a regimes jurídicos especiais, é a produção de eletricidade através de fontes renováveis, cogeração ou recursos endógenos.³

Na gestão do mix de produção existem duas características importantes que distinguem os vários tipos de produtores: despachabilidade e intermitência.

Quanto à despachabilidade, uma central de produção de eletricidade é despachável ou não-despachável dependendo do controlo sobre o momento em que pretende produzir. Por exemplo, a produção hídrica nas albufeiras é despachável porque é possível escolher o momento em que se ativam as turbinas de produção de eletricidade. Já a produção hídrica nas centrais a fio-de-água não é despachável porque não é possível escolher o momento para produzir eletricidade, ou seja, ou se produz quando há recurso ou perde-se essa capacidade de produção.

Quanto à intermitência, o tipo de produção é intermitente se não for possível controlar o momento e a quantidade de produção, estando estas dependentes de fatores exógenos ao sistema elétrico. Por exemplo, a capacidade de produção através da energia eólica, isto é, a quantidade de eletricidade que as centrais eólicas conseguem produzir num determinado momento, está dependente de fatores exógenos como a intensidade e a direção do vento. Logo, este tipo de produção é intermitente.

2.1.2. Transporte e distribuição

A transmissão de eletricidade de um centro produtor para um ponto consumidor faz-se com recurso a redes de transporte e de distribuição.

O transporte de eletricidade é feito através de redes de muito alta e alta tensão (MAT/AT) e está associado a longas distâncias, enquanto que a distribuição está associada a redes de média e baixa tensão e a ligações mais regionais. A atividade de transporte é considerada um monopólio natural enquanto que a atividade de distribuição pode ser assegurada por diversos agentes (operadores da rede de distribuição).⁴

¹ <https://www.dgeg.gov.pt/pt/areas-setoriais/energia/eficiencia-energetica/cogeracao/>

² <https://www.edp.pt/empresas/empresas-com-energia/energia-solar-fotovoltaica-ou-termica/>

³ <https://www.dgeg.gov.pt/pt/areas-setoriais/energia/energia-eletrica/producao-de-energia-eletrica/producao-em-regime-especial-renovavel-pre/enquadramento-legal/>

⁴ <https://www.portugalenergia.pt/agentes/>

Na Península Ibérica, as entidades responsáveis pelas atividades de transporte são a REN - Redes Energéticas Nacionais - e a REE - *Red Eléctrica de España*. O operador da rede de distribuição em Portugal é a E-Redes. Em Espanha, dependendo do local geográfico do consumidor, os principais operadores da rede de distribuição são a E-Redes, a Viesgo, a I-DE (Iberdrola), UFD (Naturgy) e a E-Distribución (Endesa).⁵

2.1.3. Comercialização

A comercialização é a atividade na qual são estabelecidos contratos de fornecimento de eletricidade com determinados preços, quantidades e tipo de consumo de eletricidade (BT, MT, AT e MAT) entre os agentes produtores e comercializadores ou consumidores aptos a negociar no mercado grossista.

Atualmente, em Portugal, coexistem o mercado liberalizado e o mercado regulado, permitindo assim aos clientes negociar os seus contratos de energia com um comercializador no mercado liberalizado ou permanecer no mercado regulado e pagar as TTVCF - Tarifas Transitórias de Venda a Clientes Finais (tarifas exclusivas do mercado regulado).⁶ Segundo o nível de consumo obtido em cada mercado em Portugal (figura 2.1), pode-se constatar que a evolução do mercado nos últimos anos ocorreu no sentido da liberalização.




Figura 2.1: Repartição do consumo no mercado liberalizado e no mercado regulado em Portugal de 2013 a 2017
Fonte: ERSE (2018)

Existem dois tipos de comercializadores, os Comercializadores em Regime de Mercado (CRM) e os Comercializadores de Último Recurso (CUR). Os CRM submetem as suas ofertas de compra nas diversas sessões de negociações e vendem aos clientes finais no mercado liberalizado. Os CUR atuam no mercado regulado e têm como finalidade assegurar a compra da eletricidade produzida em regime especial e a venda de eletricidade aos consumidores economicamente vulneráveis ou impossibilitados de comprar eletricidade no mercado liberalizado.⁶

Atualmente, em Portugal, toda a eletricidade PRE é adquirida no mercado regulado pelo CUR e remunerada a preços regulados para cada tecnologia. Caso a oferta exceda a procura no mercado

⁵ <https://tarifasgasluz.com/distribuidoras>

⁶ <https://www.erse.pt/atividade/regulacao/tarifas-e-precos-eletricidade/>

regulado, a PRE também será comercializada no mercado liberalizado pelo CUR. As restantes necessidades de consumo são asseguradas pela PRO.

No mercado retalhista, as comercializadoras ativas no mercado grossista concorrem para assegurar o fornecimento de eletricidade aos clientes finais, que procuram negociar com a comercializadora que lhe oferecer os melhores preços (Conselho de Reguladores do MIBEL, 2009).

O mercado da eletricidade tem também evoluído de forma a dar aos consumidores intensivos de eletricidade mais poder para participar ativamente no mercado liberalizado, o que lhes permite definir e acordar as condições de negociação de energia com a comercializadora que lhe oferecer as melhores condições, participar nos mercados dos serviços complementares e participar em associações setoriais.

No mercado liberalizado, os clientes finais podem adquirir eletricidade através de contratos bilaterais, em que o preço e quantidade são definidos pelos próprios intervenientes do contrato (mercado não organizado), ou através de contratos com preços definidos no mercado organizado (Conselho de Reguladores do MIBEL, 2009).

Na Península Ibérica, o mercado organizado é assegurado pelo MIBEL - Mercado Ibérico de Eletricidade. O MIBEL é composto pelos mercados principais e pelos mercados de ajustes. Os mercados principais são os mercados de futuros ou mercado a prazo para negociações de médio e longo prazo e o mercado diário ou *spot* para negociações de curto prazo. Os mercados de ajustes incluem o mercado intradiário e os mercados de reservas de regulação, assegurados pelo Gestor Global do Sistema (GGS) (Conselho de Reguladores do MIBEL, 2009).

Os preços dos vários tipos de contratos constituintes do MIBEL são divulgados após as sessões de negociação entre produtores e comercializadores. Nos mercados de futuros, os preços são divulgados pelo OMIP - Operador do Mercado Ibérico de energia (polo português). Nos mercados diários e intradiários os preços são divulgados pelo OMEL - Operador do Mercado Ibérico de energia (polo espanhol). Os principais mercados e os respetivos períodos de negociações estão representados na figura 2.2.




Figura 2.2: Principais mercados e os respetivos períodos de negociações

a) Mercado Diário

No mercado diário ou mercado *spot*, gerido pelo OMIE, são estabelecidos preços marginais de mercado e quantidades de eletricidade para cada hora do dia. Neste mercado, cada unidade produtora pode submeter até 24 ofertas de venda (uma para cada hora do dia seguinte), propondo determinados

preços e quantidades de eletricidade. Da mesma forma, os comercializadores e consumidores aptos a negociar no mercado grossista submetem as ofertas de compra com base no consumo previsto (Gallego, 2012).

A hora de fecho do mercado diário é às 10 horas do dia anterior. A partir das 10 horas, a OMIE gera as curvas agregadas da oferta e da procura para cada hora, colocando as ofertas por ordem de mérito, isto é, colocando o preço das ofertas de venda por ordem crescente e o preço das ofertas de compra por ordem decrescente. Por exemplo, para o dia 23 de outubro de 2007 na hora 17, a curva da oferta para o mercado português (sem importações) é apresentada na figura 2.3.




Figura 2.3: Curva da oferta de energia elétrica para o mercado português na hora 17 do dia 23 de outubro de 2007
Adaptado de: Autoridade da Concorrência (2009)

As ofertas de compra e venda negociadas neste mercado são denominadas por ofertas casadas. Os mercados de energia são marginalistas, pelo que o preço de fecho de cada sessão de negociação é comum para todas as ofertas casadas, independentemente do preço da oferta submetido por cada agente. Assim, o preço marginal de mercado é condicionado pela lei da oferta e da procura, resultando da interseção da curva da procura e da curva da oferta, tal como mostra o esquema representativo da figura 2.4 que inclui duas curvas hipotéticas da procura.




Figura 2.4: Formação do preço marginal de mercado
Fonte: Girish (2014)

A partir dos preços marginais de mercado são determinados os *baseload prices* e os *peakload prices*. Os *baseload prices* são determinados a partir da média dos preços marginais de mercado estabelecidos no mercado diário para cada hora do dia. Os *peakload prices* são determinados a partir da média dos preços marginais de mercado nas horas de maior carga (entre as 8:00h e as 20:00h).

O tipo de produção da última oferta de venda casada é denominado de tecnologia marginal, pelo que esta tecnologia determina o preço marginal de mercado. Considerando o exemplo ilustrado na figura 2.4, a tecnologia marginal seria a produção a carvão no cenário de baixa procura ou a produção a fuelóleo no cenário de elevada procura.

Após a geração das curvas agregadas da oferta e da procura para cada hora, os resultados do mercado diário são publicados no Programa Diário Base de Contratação (PDBC). O PDBC é um programa com discriminação horária das vendas e aquisições realizadas no mercado diário. A maior parte das transações de eletricidade são acordadas neste mercado (ERSE, 2013; Gallego, 2012).

As ofertas de compra no mercado diário são baseadas no consumo previsto para o dia seguinte, pelo que poderão ser necessários alguns ajustes relacionados com o erro da previsão do consumo. Os mercados de ajustes de última hora servem para resolver estes desvios bem como outras restrições técnicas que possam surgir na sequência do mercado diário, reestabelecendo o equilíbrio entre as curvas da oferta e da procura.

b) Mercado intradiário

No mercado intradiário, os preços são estabelecidos através da realização de novas sessões de negociações. Existem seis sessões de negociações no mercado intradiário para fornecimento de energia no próprio dia e/ou no dia seguinte com a distribuição de horários por sessão representada na figura 2.5 (Conselho de Reguladores do MIBEL, 2009).




Figura 2.5: Horários por sessão de negociações do mercado intradiário⁷

Devido à elevada variabilidade nas curvas da oferta e à condição necessária de equilíbrio entre as curvas da oferta e da procura para o bom funcionamento da rede elétrica, existem ainda períodos de negociações entre as sessões abertas do mercado intradiário que formam o mercado contínuo⁷ e sistemas de regulação e mecanismos de penalização às unidades produtoras que incorrem em desvios.

c) Mercado de reservas

O principal mecanismo utilizado para garantir o equilíbrio das curvas da oferta e da procura é o sistema de reservas. O sistema de reservas, gerido pela Gestão Global do Sistema (GGS), é um sistema de regulação da potência elétrica gerada nas unidades produtoras por fontes despacháveis, ou seja, este sistema só é aplicável a unidades cujo tipo de produção de eletricidade permite regular a quantidade produzida a cada momento, como por exemplo, a produção hídrica por barragens. A

⁷ <https://www.omie.es/es/mercado-de-electricidad>

quantidade reservada para regulação consiste na variação máxima da potência disponível nas unidades produtoras do sistema (ERSE, 2013).

O sistema de reservas é um serviço que contém uma componente obrigatória e uma componente complementar (mercado de reservas). É composto por três tipos de regulação:

- Regulação primária;
- Regulação secundária; e
- Reserva de regulação.

A cada tipo de regulação está associada uma quantidade de reserva obrigatória ou complementar.

A regulação primária é um sistema de carácter obrigatório que consiste em regular a potência de geração no sistema provocada por uma perda súbita de carga até 3000 MW em apenas 30 segundos através da regulação da velocidade das turbinas dos centros electroprodutores. A quantidade de reserva estabelecida para a regulação primária é determinada anualmente pela GGS através das quantidades de energia produzidas no ano anterior no SEN e no sistema síncrono interligado europeu (ERSE, 2013).

A regulação secundária é um serviço remunerado por mecanismos de mercado. A reserva de regulação secundária é determinada para cada período de programação em função da evolução temporal previsível do consumo, da probabilidade esperada de falha dos geradores ligados e da magnitude dos escalões horários de potência inerentes à programação das Unidades Físicas. As execuções neste tipo de regulação têm de estar concluídas no período de 5 minutos (ERSE, 2013).

A reserva de regulação é um serviço remunerado usado principalmente para libertar as reservas de regulação secundária, sendo complementar à atuação desta regulação. As execuções neste tipo de regulação têm de estar concluídas no período de 15 minutos (ERSE, 2013).

Nos mercados de regulação secundária e de reservas de regulação, os agentes de mercado deverão colocar à disposição da GGS a informação relativa à disponibilidade para regulação, tanto para baixar como para subir, em forma de ofertas de reserva de regulação a subir e/ou a baixar. Este serviço de fornecimento de reserva de regulação para subir e para baixar é remunerado de acordo com o preço da última oferta a ser mobilizada total ou parcialmente (ERSE, 2013).

d) Resolução de restrições técnicas

As restrições técnicas consistem em incidências nas atividades de produção ou transporte que são geridas pela GGS para que o fornecimento de energia elétrica se possa realizar nas condições de segurança, qualidade e fiabilidade de acordo com os critérios definidos pela ERSE.

A GGS recebe o Programa Diário Base de Contratação (PDBC) diariamente às 9:30 horas e após receber as ofertas para resolução de restrições técnicas, bem como outras informações relativas aos centros electroprodutores disponíveis, realiza análises de segurança e, às 13:00 horas, publica o Programa Diário Viável Definitivo (PDVD) e as necessidades de reserva. Entre as 18:00 horas e as 21:00 horas são apresentadas as ofertas do mercado de regulação secundária e, às 19 horas, a GGS comunica os resultados das ofertas. Imediatamente após a publicação dos resultados do Mercado de regulação secundária e até às 21:00 horas, os agentes de mercado submeterão à GGS ofertas de

reserva de regulação a subir e/ou a baixar e é estabelecido o Programa Horário Operativo (PHO). Estas ofertas podem ser alteradas pelos produtores em casos excepcionais, como a falta ou excesso de água nas albufeiras contíguas ou situações hidrológicas extremas em áreas de balanço com centrais hídricas (ERSE, 2013).

As restrições técnicas que surjam na sequência do mercado de ajustes são resolvidas através da anulação das transações que as originem ou que se necessite anular para concretizar o reequilíbrio entre geração e consumo. As restrições técnicas em tempo real são automaticamente corrigidas pela atuação da regulação primária e secundária, sendo os agentes de mercado remunerados pelo preço da última oferta mobilizada para subir ou descer.

e) Separação de mercados

Apesar de os mercados elétricos português e espanhol funcionarem como um único, as transações de eletricidade estão condicionadas pela capacidade de interligação entre os dois países, que, por vezes, é inferior ao volume de energia que se pretende transportar.

A formação de preços nos mercados a curto prazo está diretamente relacionada com a capacidade de interligação entre Portugal e Espanha, pois a sua insuficiência pode resultar na separação dos mercados (*Market Splitting*) e consequentemente em preços de eletricidade diferentes nos dois países. Em 2020, a capacidade média de interligação para fins comerciais foi de 2970 MW, no sentido Espanha-Portugal, e de 2925 MW, no sentido Portugal-Espanha.⁸

Se as quantidades de eletricidade destinadas para exportação ou importação através da lei da oferta e da procura forem inferiores ou iguais à capacidade de interligação no mesmo sentido, concretizam-se as transmissões na fronteira. Neste cenário, o preço da eletricidade é único para a Península Ibérica. Caso contrário, as interligações são interrompidas e os preços são formados a partir de curvas agregadas da procura e da oferta de cada país (Conselho de Reguladores do MIBEL, 2009).

f) Mercado de futuros

No mercado de futuros ou mercado a prazo são estabelecidos contratos a médio e longo prazo. Neste mercado, os agentes de mercado submetem as suas ofertas consoante a sua vontade de vender ou comprar eletricidade. Os preços são determinados através da lei da oferta e da procura, como acontece no mercado diário. Indiretamente, estas ofertas refletem a perceção que cada agente tem acerca da média do preço *spot* durante o período de entrega desse contrato, ou seja, os preços de futuros podem ser considerados como previsões do preço *spot* (Monteiro et al., 2020).

Os tipos de contrato a prazo são classificados consoante o período de entrega de eletricidade. Os contratos a prazo admitidos à negociação no MIBEL podem ser semanais, mensais, trimestrais e anuais. Para cada tipo de contrato, os preços são publicados diariamente (exceto nos fins-de-semana e feriados) pelo OMIP.

A maturidade de um contrato corresponde ao intervalo de tempo desde o início do período corrente até ao início do período de entrega. Por exemplo, um contrato mensal estabelecido no dia 29 de outubro de 2020 tem uma maturidade equivalente ao período entre o dia 1 de outubro de 2020 e o

⁸https://www.mercado.ren.pt/PT/Electr/InfoMercado/PressReleases/BibInfAnual/MercadoEletricidadeSinteseAnual2017_202104.pdf

início do mês de entrega. No mercado de futuros mensais do MIBEL são estabelecidos contratos até 6 meses de maturidade. Os preços estabelecidos nos mercados de futuros mensais para o dia 29 de outubro de 2020 encontram-se na tabela 2.1.

Tabela 2.1: Preços do mercado de futuros mensais em Portugal no dia 29 de outubro de 2020
Fonte de dados: OMIP (2020)

Mês de entrega	Maturidade (meses)	Preço (€/MWh)
Novembro de 2020	1	41.05
Dezembro de 2020	2	41.85
Janeiro de 2021	3	45.14
Fevereiro de 2021	4	44.30
Março de 2021	5	40.67
Abril de 2021	6	37.58

Atualmente, o mercado de futuros do MIBEL dispõe diariamente de contratos semanais, mensais, trimestrais e anuais até 3, 6, 7 e 7 períodos de maturidade, respetivamente, como mostra a figura 2.6. Isto significa que todos os dias estão disponíveis 23 contratos diferentes no mercado de futuros.




Figura 2.6: Contratos a prazo em 9 de outubro de 2018
Fonte: COGEN (2020)

2.1.4. Faturas de eletricidade. Composição

As faturas de eletricidade dos consumidores incluem uma componente livre e uma componente regulada. A componente livre corresponde à energia ativa, onde os preços e quantidades são negociadas no mercado grossista por intermédio de uma comercializadora. Para um consumidor em AT em Portugal, esta componente representa normalmente cerca de 70% dos custos. Os restantes 30% representam a componente regulada, que corresponde às tarifas de acesso à rede, taxas e impostos, pelo que não é possível negociar estes preços.

Tanto no mercado liberalizado como no mercado regulado, os consumidores têm acesso à rede mediante o pagamento de uma tarifa regulada pela ERSE, que permite cobrir os custos de transporte e distribuição, o custo das infraestruturas e dos serviços utilizados por todos os consumidores, incluindo, os Custos de Interesse Económico Geral (CIEG) e custos relativos a outros serviços presentes no sistema, incluindo as tarifas sociais. Os CIEG englobam o sobrecusto da PRE, o sobrecusto da PRO, o sobrecusto das Regiões Autónomas, o défice tarifário, entre outros.⁶

2.2. Preços spot e preços futuros

Os clientes finais podem adquirir eletricidade estabelecendo contratos com comercializadores, a preços fixos ou indexados ao mercado, de curto, médio ou longo prazo, sendo os mercados de futuros

⁶ <https://www.erse.pt/atividade/regulacao/tarifas-e-precos-eletricidade/>

e o mercado diário aqueles onde ocorre a maioria de transações de energia. Para analisar os preços de ambos os mercados foi considerado neste trabalho o conceito de *risk premium*.

O *risk premium* é a diferença entre a média dos preços *spot* durante um determinado período de entrega e o preço estabelecido num contrato a prazo para esse mesmo período. Este indicador reflete os ganhos ou perdas ao adquirir eletricidade no mercado de futuros relativamente ao mercado diário (*spot*). Por um lado, os mercados com contratos a prazo oferecem uma gama de preços com menores flutuações relativamente ao mercado *spot*, pelo que contribuem para uma diminuição dos riscos operacionais (Monteiro et al., 2020). Por outro lado, a evolução dos preços futuros e dos preços *spot* referentes ao mesmo período de entrega nos últimos anos indica que o preço *spot* é geralmente inferior, como mostra a figura 2.7, que permite comparar o preço *spot* com o preço de futuros mensais com maturidade de 1 mês ($M + 1$) nos dias em que este tipo de contrato é estabelecido (apenas nos dias úteis). Durante este período, o *risk premium* médio foi de -1,36.

Na maioria dos mercados de matérias-primas, genericamente, quando se aproxima o fim do período de entrega de um contrato no mercado de futuros, o preço estabelecido nesse contrato tende a aproximar-se da média do preço *spot* dessa matéria-prima durante o período de entrega (Hull, 2015). Na figura 2.7 também é possível constatar que no fim de cada mês o preço estabelecido no mercado de futuros mensais é, na maioria dos meses observados, mais próximo do preço *spot* do que o preço que tinha sido estabelecido no início do mês.




Figura 2.7: Média mensal do preço *spot* e preço de futuros mensais $M + 1$
Fonte de dados: OMIP (2020)

Um estudo aplicado ao mercado de eletricidade dos EUA revela que a aproximação dos preços futuros aos preços *spot* para o mesmo período de entrega é visível quando o consumo de eletricidade nesse período é inferior ao consumo médio (Bessembinder et al., 2002). A previsão de preços *spot* de eletricidade com base nos preços futuros de eletricidade foi aplicada em vários estudos, mostrando ser eficaz nalguns mercados europeus (Steinert, 2019).

Relativamente ao MIBEL, verifica-se a existência de uma relação significativa entre os preços *spot* e os preços futuros (mensais e trimestrais) com 1 período de maturidade (Da Silva, 2019).

Os sinais dos *risk premium* em Espanha, França e Alemanha têm uma correlação positiva, pelo que a evolução dos preços futuros em França e na Alemanha pode explicar a evolução dos preços futuros do MIBEL (Cartea, 2014).

Segundo Monteiro et al. (2020), as relações entre preços *spot* e preços futuros podem ser usadas para estabelecer estratégias de compra e venda para maximizar o lucro dos agentes do MIBEL e estas estratégias devem ser baseadas em previsões do preço *spot* a médio prazo.

2.3. Variáveis influentes nos preços de eletricidade

A curva dos preços *spot* da eletricidade tem as seguintes características (Aggarwal, 2009):

- **Elevada frequência** resultante das variações na procura e na capacidade de produção das tecnologias que dependem das condições atmosféricas;
- **Média e variância não constantes** devido a fatores socioeconómicos como preços dos combustíveis, políticas de incentivo às energias limpas, etc.;
- **Múltipla sazonalidade (semanal, anual)** devido às necessidades dos consumidores; e
- **Elevada volatilidade** devido ao elevado número de variáveis influentes no preço *spot*.

Tendo em conta estas características, os modelos de previsão de preços de eletricidade mais utilizados baseiam-se em várias variáveis. A seleção das variáveis mais significativas, aliada à qualidade da informação, toma um peso determinante na obtenção de previsões realistas (Billingsley, 1995).

Por outro lado, a acessibilidade dos dados relativos às variáveis influentes no preço e o processo de recolha e tratamento de dados também são critérios importantes para o desenvolvimento de um modelo de previsão. Assim, é fundamental ter especial atenção à seleção, pré-processamento e organização de todos os dados utilizados no processo de previsão.

2.3.1. Formação de preços grossistas

Como foi referido na secção 2.1.3, o preço marginal de mercado resulta da interseção das curvas da procura e da oferta.

A curva da procura resulta da agregação das ofertas de compra, baseadas no consumo previsto para o dia seguinte. As empresas comercializadoras fazem as suas ofertas de compra no mercado diário tendo em conta o consumo esperado dos seus clientes finais. O consumo de eletricidade depende essencialmente da temperatura atmosférica. A previsão do consumo é uma ferramenta importante para os intervenientes do mercado elétrico e alguns autores utilizam apenas a temperatura enquanto variável atmosférica para prever o consumo de eletricidade (Chapagain et al., 2017).

A curva da oferta resulta da agregação de todas as ofertas de venda das produtoras associadas à Produção em Regime Ordinário (PRO). A PRE, que depende essencialmente da intensidade do vento e do nível de precipitação, não entra na curva da oferta, dado que a sua compra é assegurada pelo CUR. Assim, a PRE não está diretamente relacionada com o preço marginal de mercado, no entanto, afeta a curva da oferta em termos de quantidade para venda (Autoridade da Concorrência, 2009).

As empresas produtoras em regime ordinário fazem as ofertas de venda em função dos custos variáveis de produção e da capacidade de produção.

a) Custos variáveis de produção

No mercado diário, a eletricidade é vendida ao preço da última oferta casada (preço marginal de mercado). As ofertas com menor preço têm maior probabilidade de participar no mercado. Assim, os custos variáveis de produção refletem os preços das ofertas de venda no sentido de maximizar a quantidade de produção.

Segundo a Autoridade da Concorrência (2009), as centrais de baixo custo de produção são utilizadas em praticamente 100% das horas (centrais de carga base), parando sobretudo para manutenção. Nas horas de maior procura, as centrais com custos variáveis de produção mais elevados também conseguem participar no mercado, marcando o preço marginal de mercado nesses períodos.

Nas centrais térmicas, os custos variáveis de produção são compostos pelos preços dos combustíveis e os preços de licenças de emissões de carbono.

Tal como no mercado de eletricidade, o mercado dos combustíveis inclui contratos de preços *spot* e de preços futuros, sendo que os preços futuros dos combustíveis também podem ser considerados como previsões do preço *spot* de eletricidade durante o mesmo período de entrega.

No seguimento do plano europeu para reduzir emissões de gases poluentes, as emissões de carbono provenientes da queima dos combustíveis tornaram-se uma importante característica que cada vez mais é incorporada no planeamento de produção de energia. O mecanismo implementado para este efeito é o Comércio Europeu de Licenças de Carbono (CELE).

O CELE é um mecanismo de regulação das emissões de Gases com Efeito de Estufa (GEE) criado pela União Europeia em 2003. A partir de 2005, este regime foi implementado com a atribuição gratuita de licenças com o objetivo de monitorizar as emissões de carbono. A partir de 2013, a atribuição de licenças de emissão para o setor da eletricidade passa a ser feita com recurso a leilão (*Decreto de Lei nº 38/2013 de 15 de março do Ministério da Agricultura, do Mar, do Ambiente e do Ordenamento do Território*, 2013).

Quanto à produção por cogeração fóssil, em Portugal é utilizado o gás natural (80%) e outros combustíveis como GPL, combustíveis líquidos e fuelóleo. Os custos variáveis de produção incluem as mesmas variáveis das centrais térmicas, contudo apresentam diferentes níveis de eficiência da central e de emissão de CO₂ por unidade de energia elétrica gerada.

Logo, quanto aos custos variáveis de produção, as principais variáveis consideradas são:

- O preço dos combustíveis, especialmente o preço do carvão e do gás natural; e
- Os preços das licenças para emissões de carbono.

b) Capacidade de produção

Para além dos custos variáveis de produção, as ofertas de venda dependem também da capacidade de produção. A capacidade de produção é a quantidade de eletricidade que uma unidade de produção consegue produzir num determinado momento. Por sua vez, esta variável está dependente da potência instalada e da capacidade de maximizar a utilização desta potência instalada na produção de energia num determinado momento.

A potência instalada é a quantidade máxima de eletricidade que uma unidade de produção consegue produzir numa hora. A potência instalada apenas sofre alterações através de

implementações de novas centrais e de medidas estratégicas que aumentam a capacidade ou melhoram a eficiência das centrais existentes.

No caso das centrais de energias renováveis sem capacidade de despacho, as condições atmosféricas determinam a quantidade de energia disponível a cada momento. A quantidade de energia eólica depende da intensidade e direção do vento, enquanto que a quantidade de energia hídrica depende do nível de precipitação e a quantidade de energia solar depende das radiações solares e da nebulosidade. É importante referir que as condições atmosféricas variam com a localização geográfica. Portanto, ao analisar a relação entre estas variáveis com a produção devem ser utilizados dados referentes à localização dos centros electroprodutores.

Relativamente às centrais hídricas por albufeiras, que têm capacidade de despacho, a quantidade de energia disponível depende do nível de armazenamento, da precipitação e das estratégias de produção por parte da empresa produtora (Autoridade da Concorrência, 2009).

No caso das energias não-renováveis e da energia nuclear, a quantidade de energia disponível está sobretudo dependente das estratégias de produção por parte da empresa produtora e do nível de eficiência da central. Neste caso, como a quantidade de energia disponível não está dependente da volatilidade associada às condições atmosféricas, a capacidade de produção das energias não-renováveis e nuclear não tem tanta influência no preço da eletricidade.

Logo, as principais variáveis que determinam a capacidade de produção são:

- A potência instalada; e
- As condições atmosféricas.

O diagrama da figura 2.8 representa a relação de causalidade entre o preço marginal de mercado e as variáveis que determinam o preço marginal de mercado e indica a disponibilidade dos dados de cada variável relativamente à Península Ibérica.

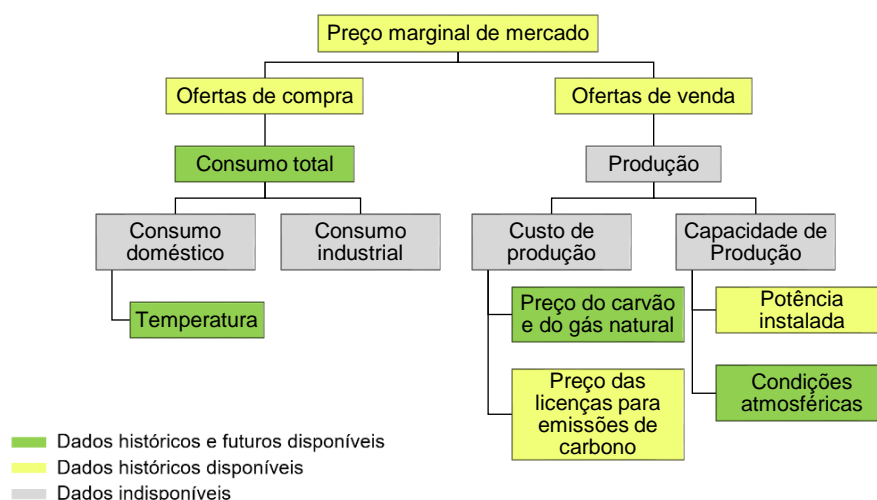


Figura 2.8: Variáveis que determinam o preço marginal de mercado do MIBEL e disponibilidade destes dados

As empresas com centrais com capacidade de despacho não se baseiam apenas nos custos variáveis de produção para definir preços de ofertas. Devido à inflexibilidade da curva da procura e às limitações da capacidade de produção de determinadas tecnologias, estas centrais seguem uma

estratégia que incorpora previsões das ofertas das empresas concorrentes. Segundo esta estratégia, o preço de oferta é baseado no custo de oportunidade.

O custo de oportunidade pode ser determinado em função do momento de negociação ou em função do tipo de produção substituto. Quanto ao momento de negociação, o custo de oportunidade é a oportunidade que uma empresa tem de obter maior lucro ao negociar determinada quantidade nos momentos em que o preço é mais elevado. Por exemplo, na produção eólica, como não é possível armazenar energia, deve ser garantida a entrada no mercado para a energia não ser desperdiçada, pelo que o seu custo de oportunidade é nulo. Já nas centrais hídricas de albufeira, estas têm um elevado custo de oportunidade porque, tendo a capacidade de armazenar água, tem a oportunidade de esperar pelas horas de maior consumo e, assim, beneficiar da venda de eletricidade nas horas em que o preço é mais elevado.

“As centrais hidroelétricas de albufeira são utilizadas com um perfil idêntico ao das centrais térmicas de maior custo de produção, marcando o preço nas horas de maior procura” (Relatório sobre a formação dos preços grossistas da energia eléctrica em Portugal no segundo semestre de 2007, 2009). Algumas destas centrais ainda podem aumentar o seu custo de oportunidade ao utilizar a tecnologia de bombagem da água de volta ao reservatório.

Quanto ao custo de oportunidade em função dos tipos de produção substitutos, as empresas produtoras que conseguem alterar rapidamente a quantidade de produção não precisam de estar sujeitas a vender por preços próximos dos seus custos variáveis de produção porque o risco de não entrar no mercado não implica que a empresa não possa vender nas horas seguintes. Por exemplo, apesar de a produção nuclear ser um tipo de produção despachável, a dificuldade em alterar rapidamente o fluxo de produção nas centrais nucleares faz com que o seu custo de oportunidade seja tão baixo quanto o custo de oportunidade das produções do tipo não-despacháveis. Neste contexto, o custo de oportunidade é a vantagem associada às empresas que não estão condicionadas a vender a preços próximos dos custos variáveis de produção para obter lucro.

Seguindo o exemplo da curva da oferta da figura 2.3, verifica-se que algumas centrais hídricas submeteram ofertas com preços acima dos 160 €/MWh na tentativa de beneficiar de uma baixa capacidade de produção dos concorrentes e de ofertas de compra com o mesmo preço. Assim sendo, as empresas produtoras com maior custo de oportunidade tendem a ficar na parte alta da curva da oferta porque as suas características permitem optar por produzir no momento que maximiza o seu lucro.

2.3.2. Fatores socioeconómicos

Os fatores socioeconómicos são responsáveis pela componente cíclica da série, isto é, pelos padrões cíclicos de período variável, e são fatores de elevada imprevisibilidade e complexidade. Portanto, são pouco utilizados nos métodos quantitativos de previsão de preços de eletricidade.

Estes fatores provocam alterações na curva do preço *spot* visíveis a longo prazo por afetarem o consumo, a potência instalada e os custos variáveis de produção. Assim, a média e a variância da curva de preços *spot* não são constantes devido a fatores socioeconómicos.

Os custos variáveis de produção e a potência instalada são afetadas por fatores económicos associados ao mercado dos combustíveis. A partir de 2020 verificou-se uma descida acentuada no

preço dos combustíveis devido à pandemia da Covid-19 que provocou uma descida no preço da eletricidade. Mais informações relativas ao impacto da covid-19 no setor elétrico podem ser consultadas no site da ERSE e no relatório elaborado pela IEA⁹.

Por outro lado, os custos variáveis de produção e a potência instalada também são afetados por fatores ambientais associados às políticas de incentivo às energias limpas. Os mercados da energia europeus têm vindo a sofrer alterações nos últimos anos devido ao esforço por parte da Comissão Europeia para fornecer aos consumidores energia segura, sustentável e a preços acessíveis. A Comissão Europeia tem como objetivo criar um mercado interno da energia mais integrado e competitivo, que visa interligar os mercados e minimizar a emissão de gases com efeito de estufa. Assim, os mercados de eletricidade europeus estão a ser remodelados de forma a promover (Erbach, 2016)^{10,11,12}:

- Energia proveniente de fontes renováveis;
- Segurança do abastecimento de eletricidade ao reduzir a sua dependência em relação às importações de energia fora do mercado europeu;
- Energia acessível para todo o tipo de consumidores. Os Estados-Membros devem assegurar uma concorrência de preços baseada no mercado e a proteção dos clientes domésticos vulneráveis e em situação de pobreza;
- Uma rede de transporte e distribuição estável e elevada capacidade de interligação entre países pertencentes à União Europeia, que provoca a convergência dos preços nestes países;
- A aproximação das políticas fiscais e de preços entre os países aderentes;
- A redução de emissões de carbono através de um regime de comércio de licenças de emissão da União Europeia, tendo como base a política que diz que qualquer entidade é cobrada por cada tonelada de carbono emitida;
- Equipamentos de alta eficiência energética; e
- A coordenação dos sistemas de regulação a nível europeu.

Estas medidas de incentivo à energia limpa provocam um aumento na volatilidade dos preços devido à crescente participação da produção intermitente no mix de produção e à inclusão de novas variáveis influentes nos preços de eletricidade como os preços de licenças de emissões de carbono.

Adicionalmente, a indústria tem respondido a medidas de incentivo ao consumo de eletricidade por parte da comissão europeia, como se pode observar pela evolução do mercado dos veículos elétricos e das bombas de calor. Considerando o cenário que incorpora as políticas governamentais criado pela *International Energy Agency* (IEA), o nível de stock de veículos elétricos será aproximadamente 140 milhões (20 vezes o nível de stocks atual)¹³.

⁹ <https://www.iea.org/reports/covid-19-impact-on-electricity>

¹⁰ <https://www.europarl.europa.eu/factsheets/pt/sheet/45/mercado-interno-da-energia>

¹¹ https://ec.europa.eu/energy/topics/renewable-energy_en

¹² <https://www.consilium.europa.eu/pt/press/press-releases/2018/12/04/energy-efficiency-renewables-governance-of-the-energy-union-council-signs-off-on-3-major-clean-energy-files/>

¹³ <https://www.iea.org/reports/global-ev-outlook-2020#prospects-for-electrification-in-transport-in-the-coming-decade>

2.4. Medidas de correlação

Existem várias medidas de correlação entre variáveis. Para analisar a relação entre o preço *spot* e as variáveis exógenas ao mercado, a medida de correlação utilizada foi o coeficiente de *Pearson*. Este coeficiente mede o grau da relação linear entre duas variáveis quantitativas, X e Y, sendo que o valor máximo (1) representa uma relação linear perfeita com declive positivo, o valor mínimo (-1) representa uma relação linear perfeita com declive negativo e um valor zero representa a ausência de uma relação linear entre as duas variáveis observadas. A figura 2.9 representa, da esquerda para a direita, uma correlação de coeficiente próximo de -1, 0 e 1, respetivamente.




Figura 2.9: Dispersão das variáveis X e Y com diferentes coeficientes de *Pearson*¹⁴

Para verificar se o coeficiente de *Pearson* (r) é significativamente diferente de zero é utilizada a equação 1, em que t representa a significância do valor obtido e n representa o número de dados da amostra. Se o valor obtido for superior ao valor de referência para um nível de confiança de 95% (1.96), então verifica-se a existência de uma relação linear entre o par de variáveis em causa.

$$t = \frac{|r|}{\sqrt{\frac{1-r^2}{n-2}}} \quad (1)$$

2.5. Modelos de previsão de preços *spot* de eletricidade

Desde o início do século XXI, várias ideias e metodologias foram testadas para prever preços de eletricidade (Weron, 2014). Esta secção descreve os modelos aplicados na previsão de preços em vários mercados de eletricidade e com objetivos distintos.

Os objetivos dos modelos de previsão de preços de eletricidade dependem das entidades interessadas na previsão de preços de eletricidade e das estratégias (de curto, médio ou longo prazo) destas entidades. Por exemplo, os produtores têm especial interesse em prever as ofertas dos seus concorrentes enquanto que os comercializadores e os consumidores têm especial interesse em prever qual o melhor momento para adquirir eletricidade. Além disso, cada entidade tem acesso a um diferente conjunto de dados, o que condiciona o desenvolvimento de um modelo de previsão.

Dependendo dos objetivos dos modelos de previsão de preços de eletricidade, estes podem ter diversas variáveis de saída (*outputs*) como os preços marginais de mercado (escala horária), os preços *spot* (escala diária), os *peakload*, entre outros. Nos mercados de estrutura *Standard Market Design* como o MIBEL, isto é, mercados compostos por um mercado diário e um mercado intradiário, a maioria dos investigadores concentram-se na previsão dos preços *spot* (Aggarwal et al., 2009).

¹⁴ <https://operdata.com.br/blog/coeficientes-de-correlacao/>

As previsões de preços podem ser determinísticas ou probabilísticas. Nas previsões probabilísticas, para além do valor estimado também são obtidas estatísticas do risco associado a essa estimativa. Os modelos probabilísticos são cada vez mais utilizados neste contexto, porém tornam o modelo mais complexo e difícil de interpretar.

Relativamente ao horizonte temporal da previsão, apesar de não existir consenso na categorização desta propriedade, as previsões de preços de eletricidade de curto prazo correspondem normalmente a um período desde alguns minutos até alguns dias. As previsões de médio prazo correspondem normalmente a um período desde alguns dias até alguns meses e a de longo prazo correspondem a um período desde alguns meses até alguns anos (Simón-Martín et al., 2020).

Weron (2014) classifica os modelos mais utilizados para a previsão de preços de eletricidade em cinco categorias. Após uma pesquisa sobre os modelos utilizados em previsão de preços de eletricidade nos últimos anos, estes foram classificados segundo a sua aplicabilidade relativamente a cada horizonte temporal de previsão (curto, médio e longo prazo), como mostra a figura 2.10.

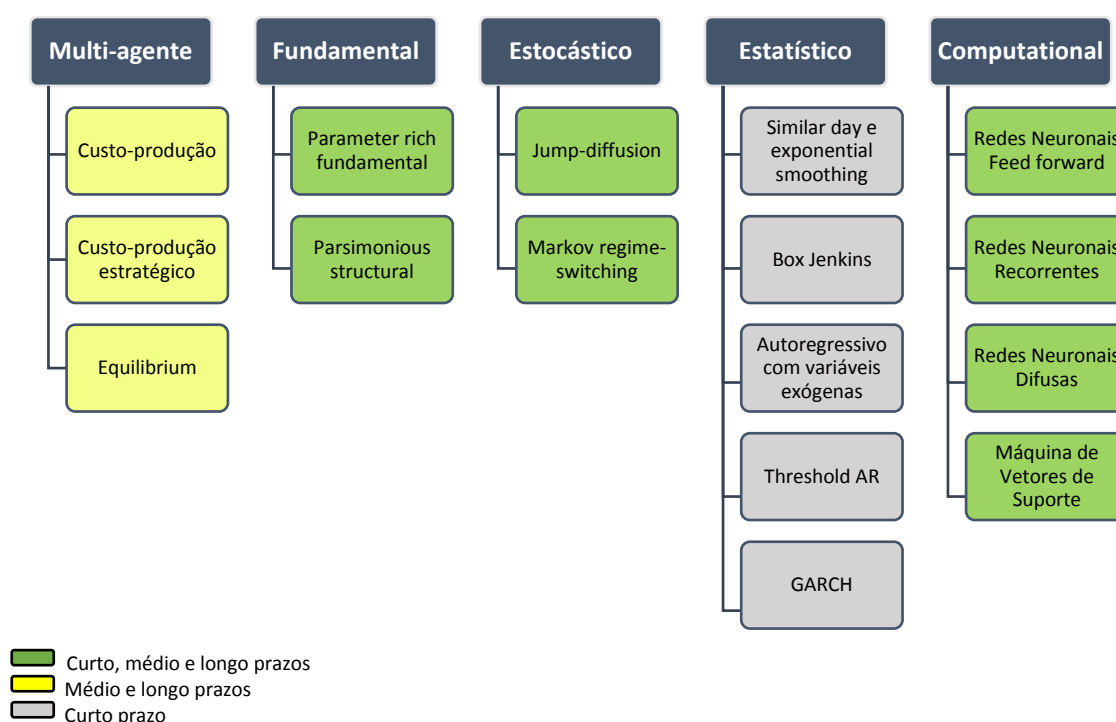


Figura 2.10: Modelos utilizados para a previsão de preços de eletricidade
Adaptado de: Weron (2014)

Os agentes do mercado de eletricidade têm mostrado cada vez mais interesse em obter previsões de médio e longo prazos. No entanto, estes modelos de previsão são mais complexos do que os de curto prazo e existem poucos estudos com resultados satisfatórios acerca da previsão a médio e longo prazos (Hong et al., 2016). Apesar dos resultados pouco satisfatórios nas previsões de médio e longo prazo, Weron (2014) considera que os modelos que podem ser utilizados neste tipo de previsão são os modelos do tipo Multi-Agente, Fundamental, Estocástico e Computacional.

2.5.1. Modelos multi-agente

Os modelos multi-agente permitem explicar o comportamento dos agentes do mercado ao modelar as curvas da oferta e da procura, a partir sobretudo dos custos de produção. Estes modelos são geralmente aplicados em mercados sem histórico de preços, normalmente para auxiliar entidades produtoras a definir estratégias de ofertas de venda através dos dados dos custos de produção da respetiva entidade produtora.

Fazem parte desta categoria os seguintes modelos:

- **Custo-produção** – É o modelo mais simples desta categoria, pois baseia-se apenas nos custos de produção de determinado agente produtor, ou seja, não considera as estratégias dos seus competidores, sendo, portanto, mais adequado em mercados regulados com preços com pouca incerteza;

- **Custo-produção estratégico** – Com o aumento da competitividade do mercado, este modelo tornou-se mais popular relativamente ao modelo Custo-produção por incluir as ações esperadas dos agentes produtores concorrentes. No entanto, só é adequado para mercados do tipo competição imperfeita, isto é, mercados com poucos agentes produtores;

- **Equilibrium** – Modelo que define o sistema com equações algébricas ou diferenciais, onde nem sempre existem soluções ou são muito difíceis de encontrar, sendo necessário recorrer a heurísticas (Mureddu and Meyer-Ortmanns, 2018). Este modelo é utilizado para estimar os preços médios e *outliers* da energia.

Como os modelos multi-agente não consideram as condições atmosféricas, que explicam grande parte das variações do preço a curto prazo, são apenas adequados para previsões de médio ou longo prazo.

Atualmente, apesar de a capacidade de explicar os comportamentos dos agentes ser interessante do ponto de vista dos produtores, os modelos do tipo multi-agente são pouco utilizados para a previsão de preços de eletricidade por requererem muitos pressupostos relativos às estratégias de ofertas de venda de cada agente, por exigirem elevados custos computacionais e pela dificuldade em aceder aos dados dos custos estruturais das entidade produtoras (Weron, 2014).

Neste contexto, a utilização de um modelo multi-agente só seria adequada se aplicada em conjunto com um modelo complementar que permitisse uma boa estimativa dos custos operacionais de produção e restantes fatores influentes nas estratégias dos agentes.

2.5.2. Modelos fundamentais

Os modelos do tipo fundamentais ou estruturais baseiam-se na relação entre o preço da eletricidade com as variáveis fundamentais, físicas ou económicas. Nestes modelos são utilizadas poucas variáveis para estimar o preço *spot*. Por exemplo, Carmona et al. (2014) utilizam o consumo de eletricidade e a temperatura atmosférica para prever o preço de eletricidade nos EUA, identificando a relação entre ambas as variáveis, consideradas pelos autores como fundamentais neste mercado.

Estas variáveis são estimadas individualmente por métodos estatísticos, estocásticos ou computacionais. Este tipo de modelos é facilmente ajustável por ser fácil de interpretar (Carmona et al., 2014).

Estes modelos permitem obter uma boa estimativa do preço quando:

- Grande parte desta série pode ser explicada com poucas variáveis;
- Existe uma elevada quantidade de dados das variáveis fundamentais disponíveis; e as
- Relações verificadas entre as variáveis não variam ao longo do tempo.

Nesta categoria estão presentes os seguintes modelos, aplicados sobretudo para previsões de médio e longo prazos:

- **Parameter-rich fundamental models** – Estes modelos baseiam-se nas variáveis que estão mais correlacionadas com o preço, sendo adequados para mercados onde um determinado tipo de produção pode explicar grande parte da série de preços (Marcjasz, 2020). Por exemplo, no mercado nórdico, a precipitação e a temperatura permitem explicar grande parte da variabilidade da série de preços de eletricidade devido à elevada concentração de produção hídrica no mix de produção desse mercado (Vahviläinen et al., 2005).

- **Parsimonious structural models** – Estes modelos baseiam-se na estrutura do sistema, ou seja, utilizam geralmente as variáveis mais relevantes na formação do preço marginal de mercado. Por exemplo, Kanamura et al. (2007) baseiam-se na relação entre o preço e o consumo para modelar a curva da oferta, como mostra a figura 2.11, assumindo que a curva da procura é inelástica.




Figura 2.11: Relação entre o preço e o consumo de eletricidade no mercado nórdico
Fonte: Kanamura et al. (2007)

Estes modelos baseiam-se em princípios semelhantes aos dos modelos computacionais. No entanto, com o desenvolvimento dos modelos computacionais, estes têm caído em desuso no que diz respeito à previsão de preços de eletricidade.

2.5.3. Modelos estocásticos

Os modelos estocásticos seguem o método da decomposição da série para modelar cada componente da série de preços separadamente através do histórico de dados e, por vezes, de variáveis exógenas.

Devido à complexidade envolvente na série de preços de eletricidade, alguns autores concentram-se na decomposição da série para detetar as componentes sazonalidade e aleatoriedade da série. Assim, alguns modelos híbridos são compostos por um método de decomposição, um modelo estatístico para modelar a componente sazonal e um computacional para modelar a componente estocástica (Simón-Martín et al., 2020), como mostra a figura 2.12.




Figura 2.12: Estrutura de um modelo híbrido com decomposição da série

Estudos recentes relativos à previsão de preços de eletricidade indicam que os modelos aplicados à série de preços decomposta permitem obter previsões mais precisas do que quando aplicados à série inicial (Marcjasz, 2020).

Quanto ao pré-processamento de dados, na previsão de preços de eletricidade são utilizadas a transformada logarítmica (que permite obter uma variância mais estável), a normalização e a remoção de *outliers*.

Os modelos estocásticos podem ser aplicados em múltiplos horizontes, normalmente numa escala diária (preços *spot*), mas os modelos estocásticos não são os mais adequados para previsões à escala horária (Weron, 2014).

Nesta categoria estão presentes os seguintes modelos:

- **Jump-diffusion** - No seguimento da decomposição da série de preços, onde é retirado o efeito sazonal e tendencial da série de preços (P_t), esta pode ser estimada a partir da equação 2.

$$dP_t = \mu(P_t, t)dt + \sigma(P_t, t)dW_t + dq(P_t, t) \quad (2)$$

Na equação 2, W_t representa um movimento aleatório responsável pelas flutuações de longo prazo; $q(P_t, t)$ representa o movimento causado pelos *spikes* (variações repentinas) através de uma distribuição de *Poisson*; $\mu(P_t, t)$ representa o movimento causado pela *mean-reversion*; $\sigma(P_t, t)$ representa a volatilidade, normalmente um valor constante.

Hess (2017) propõe um modelo do tipo *jump-diffusion* para explicar o comportamento a longo prazo da série de preços e estimar preços *spot* e preços futuros. No entanto, este modelo não consegue modelar *spikes* consecutivos.

- **Markov regime-switching** - Este modelo modela a volatilidade e ocorrência de *spikes* através de um mecanismo de transição dos parâmetros do modelo de forma aleatória. O preço estimado é dado por uma expressão ($F_{t,i}$) que difere consoante o regime r , que pode ser alterada a qualquer momento (transição de regime), como indica a equação 3.

$$P_t = \begin{cases} F_{t,1} & se & r = 1 \\ \vdots & \vdots & \vdots \\ F_{t,L} & se & r = L \end{cases} \quad (3)$$

Yan et al. (2013) propõe um modelo de *Markov regime-switching* para investigar os motivos das ocorrências de *spikes* negativos na série de preços de eletricidade a partir das variáveis exógenas ao mercado.

Estes modelos são frequentemente utilizados para explicar a série de preços com o objetivo de determinar os fatores mais influentes. Contudo, estes não são os mais populares no que diz respeito à previsão de preços de eletricidade.

2.5.4. Modelos estatísticos

Os modelos estatísticos combinam várias componentes de forma aditiva ou multiplicativa para estimar valores futuros e são muito utilizados por serem fáceis de interpretar (e se necessário ajustar), e por não necessitarem de muitos pressupostos. Estes modelos baseiam-se essencialmente na autoregressão (AR), isto é, na previsão a partir dos dados históricos da própria série. São muito utilizados nas séries estacionárias, isto é, séries em que a média e a variância não variam ao longo do tempo. Quando se trata de séries não estacionárias, como a série de preços de eletricidade (pois a média e variância variam ao longo do tempo), é necessário transformar previamente os dados da série até se obter uma série estacionária.

Nos modelos estatísticos de previsão de preços de eletricidade, as variáveis de entrada mais utilizadas são o preço, o tipo de produção mais utilizado nesse mercado e o consumo de eletricidade.

Os *Similar day and Exponential Smoothing methods* são muito utilizados na previsão do consumo de eletricidade, incluindo no mercado MIBEL, sobretudo para previsões para o dia seguinte, em escala horária (Trull et al., 2020).

Os modelos do tipo *Box Jenkins - Autorregressive (AR)*, *Moving Average (MA)* e *Autorregressive and Integrated Moving Average (ARIMA)* - permitem modelar séries complexas usando determinadas regras. Os intervalos de confiança também podem ser facilmente calculados através destes modelos. São mais adequados para previsões a curto prazo e alguns dos *softwares* mais utilizados para a aplicação destes métodos são o *Minitab*, o *SAS* e o *SPSS* (Hoshmand, 2010).

Os modelos AR são muito utilizados na previsão de condições atmosféricas e de consumo, e são frequentemente utilizados (por exemplo, com *machine learning* ou *regime-switching*) como parte de modelos híbridos para a previsão de preços de eletricidade em múltiplos horizontes, mas sobretudo

para previsões a curto prazo. São também utilizados para modelar a sazonalidade anual e os efeitos dos feriados (Weron, 2014).

Os modelos *Autorregressive with exogenous variables* (ARX) e *Autorregressive and Moving Average with exogenous variables* (ARMAX) complementam a autoregressão com regressão linear (relação com variáveis exógenas). As funções *Maximum likelihood function* (MLF) e *prediction error method* são geralmente utilizadas para a calibração do modelo. Estes modelos podem ser utilizados para previsões à escala horária (Narajewski et al., 2020). Yan et al. (2013) utilizaram um modelo híbrido composto pelos modelos ARMAX e *Least Square Support Vector Machine* (LSSVM).

O modelo *Threshold AR* tem a particularidade de incluir uma transição de regime, tal como o modelo de *markov regime-switching*, mas neste caso é possível determinar o regime aplicado em cada valor previsto.

O modelo *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) diferencia-se dos restantes desta categoria por considerar a heteroscedasticidade da série, isto é, a função da variância ao longo do tempo. Estes são muito utilizados na previsão de preços *spot*.

2.5.5. Modelos computacionais

Os modelos computacionais são modelos baseados em inteligência artificial e diferenciam-se dos restantes modelos pela capacidade de lidar com sistemas complexos e não lineares e por incluírem uma componente de aprendizagem (*machine learning*) que permite determinar automaticamente os pesos de cada variável de forma a reduzir o erro associado à previsão.

Existem muitas ferramentas baseadas em inteligência artificial aplicáveis à previsão de preços de eletricidade. Na maioria dos casos, os modelos computacionais são modelos híbridos compostos por várias ferramentas e/ou outro tipo de modelos de previsão. Por exemplo, a aplicação de modelos híbridos com uma componente computacional e uma componente estatística é muito frequente. Segundo Weron (2014), tem havido progressos com a combinação dos modelos ARIMA e redes de lógica difusa e a transformada *wavelet* (método de decomposição mais utilizado na previsão de preços de eletricidade).

As abordagens baseadas em inteligência artificial são, comparativamente aos métodos estatísticos, menos exigentes no que respeita ao tempo de computação (Weron, 2014).

Apesar do aumento da popularidade dos modelos computacionais na previsão de preços de eletricidade, a maioria das suas aplicações estão associadas à previsão do valor seguinte (*one-step ahead framework*), especialmente a previsão dos preços marginais do dia seguinte, em vez de fornecerem uma sequência de valores futuros (*multi-step ahead framework*).

Os principais modelos de computação artificial utilizados na previsão de preços de eletricidade são as Redes Neurais Artificiais (RNA), a Lógica Difusa (*Fuzzy Logic*) e as Máquinas de Vetores de Suporte (MVS).

a) Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) são muito utilizadas na previsão do preço de eletricidade do dia seguinte e são também utilizadas na previsão da procura de eletricidade. As RNA resultam da

interligação massiva de unidades de processamento simples, projetadas de forma a replicar o funcionamento do cérebro humano (Haykin, 1999). Assim, é possível considerar várias variáveis de entrada (*input*) e múltiplas combinações entre os valores das variáveis de entrada através de funções de ativação presentes em camadas intermédias (*hidden layers*) conectadas por vetores. As RNA do tipo *Deep Learning* incluem mais do que uma camada intermédia, o que permite multiplicar o número de combinações analisadas (figura 2.13).




Figura 2.13: Estrutura de uma RNA
Fonte: Bre et al. (2018)

As RNA são caracterizadas pela sua estrutura (número de variáveis de entrada e de saída, número de camadas, número de unidades de processamento e disposição dos vetores) e pelo algoritmo de aprendizagem. As RNA podem ter uma estrutura do tipo *feed-foward* ou *recurrent* (ou *feedback*).

As redes *feed-foward* têm uma única direção e um único output, por exemplo, o preço *spot* do dia seguinte, ou um conjunto de outputs, por exemplo, os preços para cada nível de tensão ou para cada hora ou ainda intervalos de confiança.

As Redes Neuronais Recorrentes (RNR) são sistemas dinâmicos pois utilizam a variável de saída como variável de entrada para o período seguinte, o que permite gerar uma sequência de *outputs*. A principal vantagem destes modelos relativamente às RNA é o facto de permitirem obter uma sequência de valores previstos (*multi-step ahead framework*), em vez de um único valor ou um conjunto de valores (*one-step ahead framework*). Ainda assim, estes modelos são mais comuns na previsão de preços de eletricidade de curto prazo.

Na previsão de preços de eletricidade, dentro das RNR destacam-se os modelos *Non-linear Autorregression with Exogenous Variables* (NARX) e *Long and Short Term Memory* (LSTM).

Os modelos NARX são modelos de Autorregressão numa RNR e as variáveis exógenas estão incluídas nas variáveis de entrada.

Apesar de também permitirem modelar várias variáveis de entrada, a principal aplicação dos modelos LSTM é a modelação de uma sequência de dados sendo utilizado, por exemplo, na ferramenta de “escrita inteligente”, pois a sua estrutura permite uma aprendizagem muito precisa do comportamento de uma sequência de dados. Estes modelos apresentam características muito semelhantes aos NARX, contudo a sua estrutura mais complexa permite “lembrar” dados antigos que possam ser relevantes e “esquecer” dados considerados irrelevantes (*forgetting gate*) para não sobrecarregar o sistema.

Uma das principais características das RNA é o algoritmo de aprendizagem, que permite determinar o peso de cada variável a partir do histórico de dados dessa variável. Segundo Weron (2014), os algoritmos de aprendizagem mais comuns para as redes *feed-forward* com várias camadas intermédias são o *back-propagation* (funções de ativação lineares ou sinusoidais) e o algoritmo de *Kernel*.

Segundo Marcjasz (2020), o algoritmo *Extreme Learning Machine* (ELM), uma ferramenta de classificação e de regressão, é tipicamente utilizado em *multi-step frameworks* para decomposição da série (componente de classificação) e para otimização dos parâmetros (componente de regressão).

O algoritmo *Sparse Autoencoder* (SAE) é uma ferramenta que, para além de determinar o peso e matriz de desvio, determina a correlação entre variáveis e inclui a componente de decomposição através da função *wavelet*, que é uma das funções que melhor modela a volatilidade da série de preços.

Weron (2014) conclui que os modelos de regressão linear (modelos estatísticos) e de RNA são, até essa data, os mais utilizados na previsão de preços de eletricidade. Desde então, os modelos RNA com *deep learning* têm ganho mais popularidade na previsão de preços de eletricidade devido ao desenvolvimento dos algoritmos de *machine learning* (Lago et al., 2018). No entanto, estes estudos concentram-se sobretudo nas previsões para o dia seguinte e ainda não existem muitos casos de sucesso no que diz respeito à previsão de preços de eletricidade a médio e longo prazos.

b) Redes de lógica difusa

As redes de lógica difusa são modelos em que as variáveis de entrada são classificadas numa determinada categoria e, posteriormente, são estabelecidas regras para todas as combinações possíveis entre as várias categorias para determinar a variável de saída. Este método de classificação prévia tem mostrado bons resultados nas previsões e, por isso, tem sido aplicado noutros modelos computacionais.

c) Máquinas de Vetores de Suporte

As Máquinas de Vetores de Suporte (MVS) são uma ferramenta de classificação (tal como a lógica difusa) e de regressão não-linear através do mapeamento dos dados para um espaço de dimensão superior ao número de variáveis e criando uma reta com regressão linear nesse espaço. Desta forma, é possível obter uma sequência de valores como output, ou seja, é possível obter previsões para vários dias seguintes (*multi-step framework*).

2.6. Modelo de Redes Neurais Artificiais treinadas com o algoritmo ELM

Estudos de casos de previsões de preços de eletricidade concentram-se sobretudo nas previsões para o dia seguinte e ainda não existem muitos casos de sucesso no que diz respeito à previsão de preços de eletricidade a médio e longo prazo. No entanto, Monteiro et al. (2020) foram bem-sucedidos ao aplicar um modelo composto por Redes Neurais Artificiais (RNA) treinada com o algoritmo *Extreme Learning Machine* (ELM) para prever o preço *spot* do mercado ibérico de eletricidade com um horizonte temporal de seis meses.

O algoritmo ELM está estruturado em três camadas, uma camada de entrada (*input layer*), uma camada intermédia (*hidden layer*) e uma camada de saída (*output layer*), como mostra a figura 2.14.




Figura 2.14: Estrutura de uma RNA treinada com o algoritmo ELM.
Adaptado de: Bre et al. (2018)

A camada de entrada é constituída por n vetores, em que n representa o número de variáveis de entrada, que formam a matriz de entrada. Esta matriz é subdividida em duas matrizes: uma para a fase de treino e outra para fase de teste.

A camada intermédia é constituída por um determinado número de células neuronais (NCN). Cada célula representa uma função de ativação que, na fase de treino, é utilizada para determinar o peso de cada variável de entrada e, na fase de teste, é utilizada para determinar o *output*.

A fase de treino é a fase em que são determinados os coeficientes do algoritmo, isto é, o vetor *Output Weight* (β). O algoritmo escolhe aleatoriamente o peso de cada valor da matriz de entrada e determina o *Output Weight* de forma a minimizar o erro, de acordo com a equação 4.

$$O_{n,d} = \sum_{i=1}^{HHN} \beta_i \cdot g(a_i \cdot x_{n,d} + b_i), \quad d = (1, 2, \dots, N) \quad (4)$$

Na equação 4, $x_{n,d}$ representa a variável n de entrada; $O_{n,d}$ representa o *output*, ou seja, a variável dependente; a_i e b_i representam o *Input Weight* e o *Bias*, respetivamente, isto é, a componente aleatória do algoritmo; g representa a função de ativação e N representa o número de dias utilizados para treino.

Monteiro et al. (2020) optaram pela função sigmoide (equação 5) como função de ativação, mas podem ser utilizadas outras funções como a função tangente hiperbólica (equação 6).

$$g = \frac{1}{1 + e^{-(a_i x_j + b_i)}} \quad (5)$$

$$g = \frac{e^{a_i x_j + b_i} - e^{-(a_i x_j + b_i)}}{e^{a_i x_j + b_i} + e^{-(a_i x_j + b_i)}} \quad (6)$$

Na fase de teste, o *output* é determinado através do *Output Weight* e da matriz de entrada destinada a esta fase. O *output* determinado é comparado com o *output* real para determinar o respetivo nível de precisão.

As variáveis incluídas neste modelo são os preços *spot* e os preços futuros mensais e trimestrais. Todos os dias (exceto fins-de-semana e feriados) são estabelecidos o preço *spot* e seis novos preços futuros mensais (*FM*) para os próximos seis meses (contratos com maturidades entre um e seis meses).

O modelo é composto por seis RNA com a mesma estrutura (apenas diferem nas variáveis de entrada e de saída), em que cada RNA devolve a previsão para o mês $M + i$ com $i = \{1, 2, \dots, 6\}$.

Monteiro et al. (2020) optaram por seis variáveis de entrada ($n = 6$), nomeadamente:

1. Mês de entrega, isto é, o valor correspondente ao mês de entrega (1 para janeiro, 2 para fevereiro, etc.). Esta variável pode ser determinada através do mês corrente $mês(d)$ e da maturidade M , de acordo com a equação 7;

$$x_{1,d} = mês_d + M \quad (7)$$

2. Número de dias entre o dia de negociação (d) e o dia anterior ao início do mês de entrega. Esta variável permite atribuir maior importância aos preços futuros mais próximos do dia de entrega;

3. Média dos preços futuros mensais para o mês de entrega (FM_i) dos últimos sete dias, de acordo com a equação 8. Desta forma, a sazonalidade semanal não interfere na previsão;

$$x_{3,d} = \frac{\sum_{i=d-7}^7 FM_i}{7} \quad (8)$$

4. Média dos preços futuros trimestrais para o mês de entrega (FT_i) dos últimos noventa dias, de acordo com a equação 9;

$$x_{4,d} = \frac{\sum_{i=d-90}^{90} FT_i}{90} \quad (9)$$

5. Média dos preços spot (S_i) dos últimos sete dias, de acordo com a equação 10;

$$x_{5,d} = \frac{\sum_{i=d-7}^7 S_i}{7} \quad (10)$$

6. Variação da média semanal dos futuros mensais nos últimos sete dias, de acordo com a equação 11. Esta variável permite determinar a evolução dos preços futuros mensais sem considerar a sazonalidade semanal.

$$x_{6,d} = x_{3,d} - x_{3,d-7} \quad (11)$$

A variável de saída ou *output* ($O_{n,d}$) é a média mensal de preços *spot*.

O modelo desenvolvido por Monteiro et al. (2020) tem como objetivo de determinar o *risk premium* associado às transações de compra e venda de eletricidade no mercado diário e no mercado de futuros mensais do MIBEL.

Durante o período utilizado para a avaliação do modelo (período de teste), o erro do modelo desenvolvido por Monteiro et al. (2020), determinado a partir do RMSE, foi de 6.12 €/MWh, enquanto que o erro associado aos preços futuros foi de 7.95 €/MWh. Logo, os resultados da avaliação do modelo de previsão obtidos demonstram que a previsão de preços *spot* foi, em média, 1.83 €/MWh mais próxima do preço *spot* verificado do que os preços futuros.

2.7. Síntese do capítulo

O sistema de elétrico nacional é composto por quatro atividades – produção, distribuição, transporte e comercialização - uma entidade reguladora (ERSE) e um gestor global do sistema (GGS),

cuja principal preocupação é a garantia da continuidade de fornecimento da energia elétrica, que só pode ser estabelecida equilibrando as curvas da oferta e da procura.

Atualmente, em Portugal, a maioria das transações de eletricidade ocorrem no mercado liberalizado, composto pelo mercado organizado (MIBEL) e pelo mercado não-organizado, através de contratos bilaterais. O MIBEL é composto pelos mercados principais a curto prazo (mercado diário) e a longo prazo (mercado de futuros) e pelos mercados de ajustes (mercado intradiário e os mercados de reservas de regulação).

Estudos demonstram a existência de uma relação entre os preços do mercado diário (preços *spot*) e os preços do mercado de futuros (preços futuros). As relações entre preços *spot* e preços futuros podem ser usadas para estabelecer estratégias de compra e venda para maximizar o lucro dos agentes do MIBEL e estas estratégias devem ser baseadas em previsões do preço *spot* a médio prazo.

No mercado liberalizado, a formação dos preços de eletricidade resulta da interseção das curvas da oferta e da procura, pelo que o preço depende do consumo, dos custos variáveis de produção e da capacidade de produção. De um modo geral, a produção por fontes renováveis depende das condições atmosféricas, que afetam a capacidade de produção, e a produção por fontes não-renováveis depende dos custos variáveis de produção, constituídos pelos preços dos combustíveis e das licenças de emissão de carbono.

Nas centrais com capacidade de despacho, a quantidade de produção depende ainda do custo de oportunidade, isto é, das estratégias de venda com base nos momentos de maior consumo e nas propostas de venda dos concorrentes.

Os custos variáveis de produção e a capacidade de produção são afetadas por fatores económicos associados ao mercado dos combustíveis e por fatores ambientais que visam melhorar a eficiência energética e minimizar a emissão de gases com efeito de estufa.

Os tipos de modelos utilizados na previsão de preços de eletricidade e respetivas características são apresentados na tabela 2.2.

Tabela 2.2 Tipos de modelos de previsão de preços *spot*

Tipo de Modelo	Características
Multi-Agente	<ul style="list-style-type: none"> São necessários dados dos custos operacionais de produção e restantes fatores influentes nas estratégias dos agentes;
Estatísticos	<ul style="list-style-type: none"> Podem ser utilizados se se verificar uma forte correlação com uma variável e se esta correlação não variar ao longo do tempo; Requerem uma elevada quantidade de dados das variáveis fundamentais; Fáceis de interpretar.
Estocásticos	<ul style="list-style-type: none"> Frequentemente utilizados para determinar os fatores mais influentes na série de preços de eletricidade.
Estatísticos	<ul style="list-style-type: none"> Frequentemente utilizados para explicar a série de preços de eletricidade; Não necessitam de muitos pressupostos; Fáceis de interpretar.
Computacionais	<ul style="list-style-type: none"> Capacidade de lidar com sistemas complexos e não lineares; Maior popularidade na previsão de preços de eletricidade devido ao desenvolvimento dos algoritmos de <i>machine learning</i>.

Apesar da maioria dos estudos de casos corresponderem a aplicações de previsões de curto prazo, Monteiro et al. (2020) apresenta um modelo computacional capaz de prever o preço *spot* para um horizonte de médio prazo (6 meses), utilizando preços futuros mensais e trimestrais.

3. Estudo de caso e análises preliminares

A Bondalti, sendo consumidora intensiva de eletricidade, pretende melhorar o processo de tomada de decisões de compra de eletricidade de forma a reduzir os custos variáveis de produção. Este capítulo apresenta a empresa, as medidas adotadas para a redução da fatura energética, as opções de compra de eletricidade e as análises preliminares à série de preços *spot* e às variáveis influentes no preço *spot*.

3.1. Enquadramento

A Bondalti-Chemicals, S.A. é uma empresa do setor da indústria química que atua no setor de **Produção de Cloro-Álcalis (PCA)** e no setor de **Produção de Anilina e Derivados (PAD)**. Estes produtos são essencialmente utilizados no processo de purificação da água, nas indústrias farmacêutica, da borracha e do papel.

O setor de PCA dedica-se essencialmente à produção de cloro gasoso, hidrogénio, soda cáustica, hipoclorito de sódio e ácido clorídrico. O processo de produção inclui o processo eletroquímico para decomposição de salmoura (solução aquosa de cloreto de sódio) e o processo eletroquímico para decomposição de ácido clorídrico.

A PCA centra-se em duas instalações de eletrólise: a instalação de eletrólise de cloreto de sódio e a instalação de eletrólise de ácido clorídrico. Estas instalações repartem entre si a capacidade total de produção de cloro gasoso.

No setor da PAD produzem-se quatro produtos finais:

- Ácido nítrico;
- Mononitrobenzeno;
- Anilina; e
- Ácido sulfanílico.

O produto principal desta cadeia é a anilina, sendo que a maioria de ácido nítrico e de Mononitrobenzeno produzidos são incorporados na produção deste produto final. O processo produtivo deste setor funciona em cadeia, sendo que o Hidrogénio, um dos sub-produtos produzidos nos processos de eletrólise da PCA, é utilizado como matéria-prima na PAD.

Para a PCA, o custo de energia elétrica representa a maior parcela dos custos de produção devido sobretudo aos processos eletroquímicos necessários para o fabrico do cloro gasoso. As instalações industriais da PAD são consumidoras intensivas de energia elétrica e de gás natural. O maior consumo energético do setor da PAD é o consumo de gás natural utilizado para a produção de vapor. A energia elétrica nestas instalações é usada para serviços gerais, força motriz, ar comprimido e arrefecimento.

Assim, para a Bondalti, o custo de energia elétrica é um fator de competitividade, já que representa a maior parcela dos custos variáveis de produção do cloro gasoso (cerca de 50% do custo total de produção). Em 2019, a Bondalti consumiu aproximadamente 358 GWh de eletricidade e 109 GWh de gás natural, com uma intensidade energética de 0.33 MWh por tonelada de produto

fabricado. Os custos de eletricidade representam cerca de 84% da fatura energética da Bondalti, sendo os restantes 16% custos com a aquisição do gás natural, utilizado essencialmente para a produção de vapor.

3.2. Medidas adotadas para reduzir o consumo de eletricidade

Tendo em conta o peso dos custos energéticos para a empresa, são definidas medidas operacionais, estratégicas, de promoção e reforço da cultura da eficiência energética, de modo a reduzir os consumos específicos de energia e as emissões de carbono, e medidas que visam a redução da fatura energética. Por exemplo, uma das medidas estratégicas adotadas para redução do consumo energético é a implementação de novos equipamentos e tecnologias mais eficientes.

Sendo o custo de energia elétrica tão importante para a Bondalti, esta desenvolve medidas de redução da fatura energética, tais como:

- A definição de estratégias de aquisição de energia que permitam reduzir o risco de exposição à volatilidade do mercado;
- O acompanhamento dos preços de mercado dos indexantes do contrato de gás natural;
- A participação em mecanismos de reserva que promovem a flexibilidade do consumo, isto é, mecanismos de redução ou aumento voluntário do seu consumo de eletricidade em resposta à necessidade do operador da rede de transporte;
- O controlo da potência elétrica contratada e da capacidade diária de gás natural consumida;
- A modulação de cargas por período tarifário, planeando o consumo preferencialmente nos períodos menos onerados pelo tarifário em vigor; e
- A implementação do Sistema de Gestão de Energia pela norma ISO 50001, que estabelece parâmetros internacionais para o uso e consumo de energia em organizações industriais de modo a melhorar o desempenho energético.

3.3. Estratégias de compra de eletricidade

A equipa de gestão da energia da Bondalti gere a aquisição de eletricidade e gás natural através de diferentes contratos de aquisição com diferentes empresas comercializadoras. Cada comercializadora apresenta uma proposta para a venda de eletricidade que pode basear-se em preços fixos ou preços indexados ao valor dos mercados grossistas de eletricidade da Península Ibérica. A equipa de gestão de energia analisa as várias propostas e propõe à sua administração a proposta mais eficiente.

Os preços de cada mercado são divulgados consoante as ofertas de compra e de venda nesse mercado, exceto nos contratos bilaterais, em que o preço é acordado entre o consumidor e o produtor ou comercializador. Nestes contratos, quando não é fechada a totalidade da energia a consumir em mercado de futuros, a restante energia é transacionada a preços de mercado diário (preços *spot*). Nos mercados de futuros e no mercado diário, os preços estabelecidos correspondem à média dos preços para cada hora do dia. Ao longo do dia existem quatro períodos com preços diferentes: Super Vazio, Vazio, Ponta e Cheia.

Quanto às opções de compra de eletricidade, a Bondalti tem a possibilidade de:

- **Negociar em contratação bilateral.** Um dos tipos de contratação bilateral são os *Power Purchase Agreement* (PPA), que consistem num acordo de compra e venda de energia renovável de longo prazo;
- **Negociar uma percentagem das necessidades de consumo previstas nos mercados de futuros (semanais, mensais, trimestrais ou anuais);**
- **Apresentar ofertas no mercado intradiário** relativas ao consumo no próprio dia ou no dia seguinte; e
- **Apresentar ofertas no mercado contínuo e no mercado de reservas de regulação** relativas ao consumo no próprio dia.

Atualmente, para reduzir a fatura de eletricidade, a Bondalti define estrategicamente quais os momentos em que deve negociar a aquisição de energia, procurando os mercados que ofereçam os melhores preços. Para isso, a Bondalti analisa diariamente a evolução dos preços nos diversos mercados e estabelece objetivos para preços para cada período. Esta análise implica a monitorização dos preços dos principais mercados de eletricidade em Portugal, Espanha, França e Alemanha, assim como os preços dos combustíveis e outros dados referentes ao MIBEL.

3.4. Modelo de apoio à decisão de aquisição de eletricidade

A estimativa de preços *spot* a médio prazo permite estabelecer uma análise comparativa entre os preços atuais do mercado de futuros (mensais e trimestrais) e os preços estimados no mercado diário durante o mesmo período de entrega de eletricidade.

Um modelo de previsão de preços *spot* de eletricidade permite determinar se o preço estabelecido nos mercados futuros num determinado dia é inferior ou superior à média de preços *spot* estimados durante o período de entrega estabelecido no contrato de aquisição de eletricidade do mercado de futuros em que se considera negociar nesse dia.

Por exemplo, no dia 29 de outubro de 2020, o preço do mercado de futuros mensais para novembro de 2020 foi de 41.05 €/MWh. Supondo que a Bondalti tem, até esse dia, contratos estabelecidos para a aquisição de 90% das necessidades de consumo de eletricidade definidas para novembro de 2020, a equipa de gestão de energia da Bondalti considera duas hipóteses de aquisição para os restantes 10% do consumo de eletricidade em novembro:

- **Hipótese 1)** Negociar os restantes 10% neste mercado, ou seja, adquirir 10% do consumo de eletricidade em novembro por 41.05 €/MWh;
- **Hipótese 2)** Não negociar no mercado de futuros, ficando sujeita aos preços do mercado diário (preços *spot*).

A hipótese 1 seria a opção mais eficiente no caso da média de preços *spot* em novembro ser superior a 41.05 €/MWh. Assim, com os resultados do modelo de previsão de preços *spot* relativos ao mês de entrega (novembro de 2020) será possível selecionar a hipótese é a mais eficiente.

A quantidade de eletricidade não negociada no mercado de futuros é geralmente adquirida no mercado diário. Logo, um modelo de previsão de preços *spot* de eletricidade é uma ferramenta que pode melhorar a eficiência da empresa no que diz respeito à aquisição de eletricidade.

3.5. Preços *spot* de eletricidade

Foram analisadas as séries dos preços *spot* de eletricidade em Portugal e em Espanha (valores diários) entre 1 de janeiro de 2016 e 31 de dezembro de 2020. O preço *spot* em Portugal é estabelecido pelas curvas associadas à procura e oferta do mercado da Península Ibérica, exceto na situação em que existe separação de mercados (descrita na secção 2.1.3). Atualmente, a capacidade de interligação entre Portugal e Espanha é suficiente na maioria das horas. De 1 de janeiro de 2019 a 31 de dezembro de 2020, a probabilidade de ocorrência de separação de mercados foi de 18% e a diferença absoluta média entre os preços *spot* em Portugal e Espanha foi de 0.18 €/MWh, o que representa 0.4% da média do preço *spot* durante este período (40.86 €/MWh).

No entanto, é importante referir que, no caso em que ocorre a separação de mercados, o preço em Portugal é geralmente superior ao preço de Espanha. Por exemplo, em março de 2019 a separação de mercados provocou uma diferença de preços nos dois países, como mostra a figura 3.1. Nesse mês, a média de preços *spot* em Portugal foi de 49.20 €/MWh e a média de preços *spot* em Espanha foi de 48.82 €/MWh.




Figura 3.1: Preços *spot* em Espanha e em Portugal em março de 2019
Fonte de dados: OMIP (2020)

Durante o mês de março de 2019, verifica-se também que a diferença máxima entre preços *spot* em Portugal e preços *spot* em Espanha foi de 3,80 €/MWh (dia 17 de março). Logo, para as previsões de preços *spot* em Portugal ou em Espanha a curto prazo deve ter-se em consideração a capacidade de transporte de eletricidade na fronteira (capacidade de interligação). No entanto, na maioria dos dias houve sobreposição dos valores, pelo que nos modelos de previsão a longo prazo, a capacidade de interligação é pouco relevante.

Tendo em conta que o preço *spot* de eletricidade em Portugal é formado no Mercado Ibérico da Eletricidade (MIBEL), com exceção nos momentos em que ocorre o fenómeno de separação de mercados, os dados recolhidos e analisados do consumo e da produção de eletricidade analisados são referentes à Península Ibérica.

A partir dos preços *spot* verificados em Portugal nos últimos cinco anos verifica-se que o preço médio foi de 46.42 €/MWh e a variância foi de 13.90² €/MWh. No entanto, em termos mensais, a média e a variância da série não são constantes, como mostra a figura 3.2.




Figura 3.2: Média mensal e variância do preço *spot* entre janeiro de 2016 e dezembro de 2020
Fonte de dados: OMIP (2021)

Através da evolução da média mensal de preços *spot* durante o período em análise verifica-se que, com a exceção do ano de 2019, parece existir um aumento entre maio e setembro. A partir da evolução da variância verifica-se que esta é normalmente maior no início e fim de cada ano, mostrando a existência de maior variabilidade nos preços nestes períodos. Estes comportamentos na série de preços parecem indicar a existência de sazonalidade. Assim, é em seguida analisada a existência de sazonalidade semanal, mensal e anual.

Para verificar a existência de sazonalidade semanal na série de preços *spot*, foi determinada a autocorrelação desta série com um desfaseamento de sete dias através do coeficiente de *Pearson* (r).

Para determinar se o valor obtido (0.84) é significativamente diferente de zero, para um nível de confiança de 95%, foi determinada a significância do valor obtido (t) a partir do número de dados da amostra ($n = 1820$ dias), de acordo com a equação 1. Como a significância do valor obtido deste coeficiente (64.89) é superior ao valor de referência para uma significância de 95% (1.96), verifica-se a existência de sazonalidade semanal. Assim, verifica-se em cada semana o comportamento da curva apresentado na figura 3.3 através dos fatores sazonais semanais obtidos.




Figura 3.3: Fatores sazonais semanais
Fonte de dados: OMIP (2021)

Verifica-se que, em média, atingem-se valores mais elevados na terça-feira (+2.08 €/MWh) e reduzidos no fim de semana, nomeadamente no domingo (-5.71 €/MWh).

Para verificar a existência de sazonalidade mensal na série de preços *spot*, foi removida a sazonalidade semanal através dos fatores sazonais semanais. Para o efeito, foram determinadas as diferenças sazonais semanais ao subtrair a série de preços *spot* pela média móvel centrada de sete preços diários. Os fatores sazonais semanais foram determinados agrupando as diferenças sazonais semanais de acordo com o dia da semana. De seguida, os fatores sazonais semanais foram ajustados de modo a que a sua média seja igual a zero.

A série de preços *spot* dessazonalizada semanalmente foi obtida através da diferença entre a série de preços *spot* original e os fatores sazonais semanais ajustados. De seguida, foram determinadas as diferenças sazonais mensais ao subtrair a série de preços *spot* dessazonalizada pela média móvel centrada de 30 preços diários. Os fatores sazonais mensais foram determinados agrupando as diferenças sazonais mensais de acordo com o dia do mês. Os fatores sazonais mensais foram ajustados de modo a que a sua média seja igual a zero.

A existência de sazonalidade mensal foi verificada através da normalização dos fatores sazonais mensais, obtida de acordo com a equação 12.

$$Z_i = \left| \frac{FS_{mensal,i} - 0}{S_{FS_{mensal,i}/\sqrt{n}}} \right|, \text{ com } i = 1, 2, \dots, 31 \quad (12)$$

Na equação 12, $FS_{mensal,i}$ representa o fator sazonal mensal para o dia i , $S_{FS_{mensal,i}}$ representa o desvio padrão das diferenças sazonais mensais para o dia do mês i e n representa a amostra de diferenças sazonais para o dia do mês i . A significância de 6 dos 31 fatores sazonais é superior ao valor de referência para uma significância de 95% (1.96), pelo que se verifica a existência de sazonalidade mensal. Assim, verifica-se em cada mês com 31 dias o comportamento da curva apresentado na figura 3.4 através dos fatores sazonais mensais obtidos.



Figura 3.4: Fatores sazonais mensais
Fonte de dados: OMIP (2021)

Verifica-se que, em média, atingem-se valores mais elevados no dia 23 (+1.71 €/MWh) e reduzidos no dia 2 (-1.41 €/MWh).

Para verificar a existência de sazonalidade anual na série de preços *spot*, foi removida a sazonalidade mensal. Para o efeito, a série de preços *spot* dessazonalizada mensalmente foi obtida através da diferença entre a série de preços *spot* dessazonalizada semanalmente e os fatores sazonais mensais.

Foram determinadas as diferenças sazonais anuais ao subtrair a série de preços *spot* dessazonalizada mensalmente pela média móvel centrada de 365 preço diários. Os fatores sazonais anuais foram determinados agrupando as diferenças sazonais anuais por dia do ano. De seguida, os fatores sazonais anuais foram ajustados de modo a que a sua média seja igual a zero.

A existência de sazonalidade anual foi verificada através da normalização dos fatores sazonais anuais, obtida de acordo com a equação 13.

$$Z_i = \left| \frac{FS_{anual,i} - 0}{S_{FS_{anual,i}}/\sqrt{n}} \right|, \quad \text{com } i = 1, 2, \dots, 366 \quad (13)$$

Na equação 13, $FS_{anual,i}$ representa o fator sazonal anual para o dia do ano i , $S_{FS_{anual,i}}$ representa o desvio padrão dos fatores sazonais anuais para o dia do ano i e n representa a amostra de diferenças sazonais para o dia do ano i . A significância de 150 dos 366 fatores sazonais anuais é superior ao valor de referência para uma significância de 95% (1.96), pelo que se verifica a existência de sazonalidade anual. Assim, verifica-se em cada ano com 366 dias o comportamento da curva apresentado na figura 3.5, através dos fatores sazonais anuais obtidos.




Figura 3.5: Fatores sazonais anuais
Fonte de dados: OMIP (2021)

Verifica-se que, em média, atingiram-se valores mais elevados a 25 de janeiro (+14.63 €/MWh) e reduzidos a 29 de março (-17.48 €/MWh).

3.6. Análise de variáveis influentes no preço *spot*

Tendo em conta a volatilidade da série de preços *spot*, realiza-se a análise das variáveis influentes no preço *spot* de forma a identificar as que melhor explicam a volatilidade desta série. Para o efeito, as variáveis foram analisadas isoladamente para identificar o seu impacto no preço *spot*. Deste modo, podem ser identificadas aquelas que têm maior impacto no preço *spot* e por isso devem ser consideradas no modelo de previsão de preços *spot* de eletricidade.

Para analisar o impacto das variáveis influentes no preço *spot* foram recolhidos os dados históricos das seguintes variáveis:

- **Tecnologias marginais** em Portugal, disponibilizados pela OMIE;
- **Consumo final e quantidade injetada na rede**, que difere do consumo final devido às perdas no transporte, na Península Ibérica, disponibilizado pela REE;

- **Consumo total** em Portugal, disponibilizado pela REN;
- **Consumo anual por tipo de consumidor (industrial, doméstico normais, não doméstico, entre outros)** em Portugal, disponibilizado pela DGEG;
- **Temperatura atmosférica** em Madrid, disponibilizada pela Visual Crossing;
- **Produção por tecnologia** na Península Ibérica, disponibilizada pela REE;
- **Preços spot e futuros do gás natural** na Península Ibérica, disponibilizados pelo (*Mercado Ibérico del Gas*) MIBGÁS;
- **Quantidade de carbono emitida por tecnologia** na Península Ibérica, disponibilizada pela REE; e
- **Potência instalada por tecnologia** em Portugal, disponibilizada pela DGEG.

3.6.1. Consumo

O consumo é a variável exógena mais utilizada em modelos de previsão de preços de eletricidade de médio e longo prazo (Ziel et al., 2018). Para analisar o comportamento do consumo de eletricidade e a sua relação com o preço *spot* de eletricidade foram recolhidos dados diários e mensais entre 1 de janeiro de 2016 e 31 de dezembro de 2020. A evolução da média mensal do consumo na Península Ibérica, apresentada na figura 3.6, mostra que o consumo mensal geralmente atinge valores mínimos em abril e outubro e valores máximos em janeiro e julho.




Figura 3.6: Média mensal do consumo de eletricidade na Península Ibérica de 1 de janeiro de 2016 a 31 de dezembro de 2019
Fonte de dados: REE (2021)

Com base no consumo mensal na Península Ibérica entre 2016 e 2019, foi determinado o coeficiente de *Pearson* entre o consumo no mês M e o consumo no mês $M + 12$. Como a significância do valor obtido deste coeficiente (6.65) é superior ao valor de referência para uma significância de 95% (1.96), verifica-se a existência de sazonalidade anual.

Ao observar a evolução da temperatura média mensal em Madrid durante o mesmo período verifica-se que os valores máximos de consumo correspondem a valores baixos e elevados da temperatura média em Madrid, como mostra a figura 3.7. Assim pode concluir-se que, na Península Ibérica, o consumo está diretamente relacionado com o afastamento da temperatura do seu próprio valor médio (15,7 °C).




Figura 3.7: Consumo de eletricidade na Península Ibérica e temperatura atmosférica em Madrid de 1 de janeiro de 2016 a 31 de dezembro de 2019

Fonte de dados: REE (2021) e Visual Crossing (2021)

De seguida, foram analisados os valores diários do consumo no mesmo período. Na figura 3.8 é possível observar a evolução do consumo na Península Ibérica ao longo do ano de 2019, o ano anterior à pandemia.




Figura 3.8: Consumo de eletricidade na Península Ibérica em 2019

Fonte de dados: REE (2021)

Com base no consumo diário na Península Ibérica entre 1 de janeiro de 2016 e 31 de dezembro de 2019, apresentado na figura 3.8, parece haver sazonalidade semanal, isto é, de sete dias. Por isso, foi determinado o coeficiente de *Pearson* entre o consumo no dia D e o consumo no dia D + 7. Como a significância do valor obtido deste coeficiente (50.81) é superior ao valor de referência para uma significância de 95% (1.96), verifica-se, tal como no preço *spot*, a existência de sazonalidade semanal.

Ao agrupar os dados analisados por dia da semana verifica-se um padrão semanal semelhante ao do preço *spot*, em que os valores correspondentes aos dias úteis são superiores aos dos fins-de-semana e ambas as séries atingem valores mínimos no domingo e valores máximos na quarta-feira, como mostra a figura 3.9. Assim pode-se concluir que a série de consumo tem um padrão semanal semelhante ao da série de preços *spot*.




Figura 3.9: Consumo médio de eletricidade na Península Ibérica e preço *spot* por dia da semana de 1 de janeiro de 2016 a 31 de dezembro de 2019

Fonte de dados: REE (2021)

Caso o objetivo do modelo de previsão seja estimar a média mensal do preço *spot*, as séries de dados históricos do preço *spot* e do consumo devem ser analisadas para verificar se têm um comportamento semelhante, para além do padrão semanal identificado. Consequentemente, é em seguida realizada essa análise.

Para isso, foram calculadas as médias móveis de sete dias do consumo e do preço *spot*, retirando o efeito de sazonalidade semanal de ambas as séries. Através da figura 3.10, que mostra a evolução das duas variáveis ao longo de 2019, verifica-se que em determinadas ocasiões a variação do consumo parece provocar uma variação no preço *spot* no mesmo sentido. Por exemplo, a subida do preço *spot* entre novembro e dezembro de 2019 pode estar relacionada com o aumento do consumo no mesmo período.




Figura 3.10: Médias do consumo de eletricidade na Península Ibérica e do preço *spot* nos últimos sete dias em 2019
Fonte de dados: REE e OMIP (2021)

O consumo pode dar indícios de variações na média mensal do preço *spot*. Por outro lado, as componentes de sazonalidade existentes na série do consumo analisada podem ajudar na previsão desta variável. Adicionalmente, a REE disponibiliza uma previsão do consumo em Portugal com um horizonte temporal de 15 dias. Logo, esta variável pode ser uma potencial variável a considerar num modelo de previsão de preços *spot*.

3.6.2. Produção

Para determinar os tipos de produção com maior influência no preço *spot* foram consideradas as quantidades produzidas (mix de produção), as tecnologias marginais e a potência instalada por tipo de produção. Apesar da atipicidade do ano de 2020 provocada pela pandemia da Covid-19, também foram considerados os dados relativos à produção durante este ano para observar as tendências do mercado a longo prazo.

a) Mix de produção

O mix de produção representa a importância de cada tipo de produção no mercado de eletricidade, isto é, a quantidade produzida de cada tipo de produção relativa à quantidade total produzida. Para analisar as tendências a longo prazo no mix de produção, as quantidades produzidas por tipo de produção foram observadas à escala anual. A figura 3.11 apresenta a evolução da produção para os oito tipos de produção na Península Ibérica e o mix de produção resultante dos cinco anos, de 2016 a 2020.




Figura 3.11: Evolução de cada tipo de produção entre 2016 e 2020 e mix de produção resultante dos 5 anos
Fonte de dados: REE (2021)

De acordo com o mix de produção, as tecnologias mais utilizadas para a produção de eletricidade na Península Ibérica são a energia nuclear, com uma participação de 23% no mercado diário, seguida da energia eólica, com uma participação de 21%. Verifica-se também que os tipos de produção que apresentam maior variabilidade ao longo dos cinco anos são a produção a carvão, a produção por ciclo combinado e a produção hídrica.

Para determinar o impacto de cada variável no preço devem ser analisadas as relações entre cada variável e o preço. Para o efeito, foram determinadas, através do coeficiente de *Pearson*, as correlações entre o preço *spot* e as quantidades produzidas por cada tecnologia. Tendo em conta que as amostras das variáveis utilizadas nesta análise são constituídas por 48 dados, de acordo com a equação 1, para um nível de confiança de 95%, verifica-se a existência de uma relação linear caso o coeficiente de *Pearson* atinga valores fora do intervalo $[-0.28, 0.28]$.

O mesmo procedimento foi aplicado com o preço do gás natural (preço GN) e o consumo da Península Ibérica, de modo a averiguar a relação destas variáveis com o preço *spot*. Os resultados desta análise são apresentados na figura 3.12.

	Consumo	Hídrica	Eólica	Resíduos não renováveis	Solar fotovoltaica	Solar térmica	Carvão	Ciclo combinado	Cogeração fóssil	Outras renováveis	Resíduos Renováveis	Nuclear	Preço GN
Preço spot	0.27	-0.57	-0.29	0.18	-0.22	-0.12	0.58	0.24	0.70	0.58	0.44	0.02	0.80
Consumo		-0.07	0.27	0.44	-0.26	-0.14	0.40	0.03	0.16	0.45	0.50	0.25	0.37
Hídrica			0.39	-0.34	-0.12	-0.19	-0.39	-0.62	-0.42	-0.63	-0.47	-0.21	-0.13
Eólica				-0.08	-0.55	-0.63	-0.28	-0.28	0.08	-0.34	0.02	-0.08	0.02
Resíduos não renováveis					-0.23	-0.03	0.66	-0.18	-0.18	0.28	0.52	0.47	0.29
Solar fotovoltaica						0.94	-0.37	0.25	-0.13	0.07	-0.24	0.13	-0.50
Solar térmica							-0.13	0.17	-0.21	0.15	-0.16	0.15	-0.37
Carvão								-0.19	0.01	0.43	0.30	0.03	0.68
Ciclo combinado									0.37	0.49	0.33	-0.04	-0.25
Cogeração fóssil										0.40	0.41	-0.10	0.39
Outras renováveis											0.51	0.06	0.25
Resíduos Renováveis												0.28	0.28
Nuclear													0.00

Figura 3.12: Matriz de correlações
Fonte de dados: OMIP (2021), REN (2021), REE (2021) e MIBGÁS (2021)

Como os valores obtidos do coeficiente de *Pearson* entre o preço *spot* e as produções hídrica, eólica e solar são negativos, estes tipos de produção variam no sentido inverso do preço *spot*, o que

significa que estas são as tecnologias que requerem menores custos variáveis de produção. Por exemplo, o preço *spot* é geralmente mais baixo quando a produção hídrica aumenta, como mostra a figura 3.13.




Figura 3.13: Relação entre o preço *spot* e a produção hídrica
Fonte de dados: OMIP e REE (2021)

De entre os pares de variáveis analisadas, o preço do gás natural foi a variável com maior correlação com o preço *spot* (0,8), seguida da produção por cogeração fóssil (0,7). A forte associação entre o preço *spot* e o preço do gás natural também pode ser observada quando comparadas as evoluções de ambas as variáveis, como mostra a figura 3.14.




Figura 3.14: Evolução do preço *spot* de eletricidade e preço do gás natural de 1 de janeiro de 2016 a 31 de outubro de 2020
Fonte de dados: OMIP e MIBGÁS (2021)

Através da matriz de correlações (figura 3.12) também é possível analisar as associações entre o preço do gás natural e as produções nas centrais térmicas (0.68, -0.25 e 0.39), na qual se verifica que as centrais térmicas a carvão estão mais dependentes do preço do gás natural do que as centrais de ciclo combinado ou de cogeração fóssil, que utilizam para além deste, também outros combustíveis.

b) Tecnologias marginais

Como foi referido na secção 2.1.3, a tecnologia marginal é o tipo de produção que determina o preço marginal de mercado. Consequentemente, esta variável também pode dar indícios acerca da contribuição de cada tipo de produção na formação do preço *spot*.

As tecnologias marginais diferem entre Portugal e Espanha devido ao fenómeno de separação de mercados. Para esta análise foram apenas consideradas as tecnologias marginais em Portugal de modo a considerar o efeito provocado por este fenómeno. Assim, foram recolhidos os dados das tecnologias marginais em Portugal desde 1 de janeiro de 2016 a 31 de dezembro de 2020.

Através do número de ocorrências em que cada conjunto de tecnologias contém a tecnologia marginal foram determinadas as probabilidades de cada conjunto de tecnologias incluir a tecnologia

marginal. A evolução das tecnologias marginais em Portugal de 2016 a 2020 e a probabilidade de cada tipo de produção ser tecnologia marginal estão ilustradas na figura 3.15.




Figura 3.15: Evolução das tecnologias marginais em Portugal e percentagem de ocorrências da tecnologia marginal em cada grupo de 2016 a 2020
Fonte de dados: OMIE (2021)

Com base nos dados obtidos verifica-se que nos últimos anos a produção hídrica foi o tipo de produção que determinou o preço marginal de mercado em mais ocasiões. Este tipo de produção surgiu na parte alta da curva de oferta em pelo menos 51% das horas. Como não foi observada qualquer ocorrência em que a produção nuclear tenha sido tecnologia marginal, pode-se concluir que as centrais nucleares são centrais de carga base por ter um custo de produção competitivo e pelo interesse em manter a produção em níveis estáveis (devido à tecnologia).

Ao observar-se as ocorrências em que cada tipo de produção foi tecnologia marginal por ano, verifica-se também que o número de ocorrências em que a produção térmica convencional foi tecnologia marginal começa a diminuir a partir de 2018, de 1509 ocorrências (24%) para 235 ocorrências verificadas em 2020 (6%). Por outro lado, o número de ocorrências em que a produção por energias renováveis, cogeração e resíduos foi tecnologia marginal começa a aumentar a partir de 2018 de 1057 ocorrências (13%) para 2009 ocorrências verificadas em 2020 (23%).

Como as produtoras hídricas têm capacidade de armazenamento e, nas centrais hídricas reversíveis, a possibilidade de aumentar o nível de armazenamento através do processo de bombagem, estas produtoras optam por abastecer a albufeira de água durante as horas de menor consumo para aumentar a produção nas horas de maior consumo. Esta estratégia, que tem em conta o custo de oportunidade, permite-lhes uma maior participação no mercado durante as horas de maior consumo. Devido ao aumento da produção nas horas de maior consumo, a produção hídrica é a tecnologia marginal mais frequente neste período, como mostra a figura 3.16.




Figura 3.16: Número de ocorrências em que cada tipo de produção foi tecnologia marginal por hora e média horária do consumo entre 1 de janeiro de 2016 e 31 de dezembro de 2020
Fonte de dados: OMIE e REE (2021)

Ao associar o preço marginal de mercado com a tecnologia marginal, verifica-se que o preço marginal de mercado é superior quando determinado pela produção hídrica e inferior quando determinado pela produção térmica convencional, como mostra a figura 3.17. Foi também calculado o desvio-padrão do preço marginal de mercado por tecnologia marginal, ilustrado na figura 3.17 através das barras de erro.

Segundo a lei da oferta e da procura, o preço aumenta com o aumento do consumo. Através da figura 3.17, verifica-se que o preço marginal de mercado é superior quando a produção hídrica determina o preço, o que evidencia a estratégia do custo de oportunidade na formação do preço destas ofertas de venda, isto é, a estratégia de aumentar a capacidade de produção nas horas de maior consumo.

As centrais térmicas, apesar de não terem uma tecnologia reversível, também têm a capacidade de armazenar a sua matéria-prima, o que permite às equipas de gestão incluir o custo de oportunidade nas suas estratégias. Porém, como os custos variáveis de produção são superiores, o custo de oportunidade nestas centrais é inferior. Assim, o preço marginal de mercado quando este tipo de produção marca o preço também é inferior.




Figura 3.17: Média do preço marginal de mercado em função da tecnologia marginal por ano
Fonte de dados: OMIE (2021)

É importante referir que, apesar do preço ser menor quando a produção térmica determina o preço, estes tipos de produção não têm um impacto negativo no preço, como mostra a matriz de correlações (figura 3.12).

A capacidade de produção das energias renováveis também está dependente de fatores externos, condições atmosféricas, pelo que a variabilidade dos preços de ofertas por parte deste tipo de centrais também é superior. Por exemplo, nos meses de menor ou nenhuma precipitação, a capacidade de produção das centrais hídricas é menor, o que provoca uma maior competição no mercado. Neste cenário verifica-se que o preço é semelhante quando determinado pela produção hídrica ou pela produção térmica convencional. Assim, quando a capacidade de produção das centrais hídricas diminui, os preços das suas ofertas de venda têm de ser inferiores para assegurar as vendas.

Adicionalmente, esta tecnologia também beneficia do elevado custo de oportunidade em função do tipo de produção substituto, isto é, a produção hídrica não necessita de estar sujeita a vender por preços reduzidos porque tem a opção de produzir noutra hora se não entrar no mercado, ao contrário das tecnologias sem capacidade de despacho como a energia eólica. Ou seja, mesmo considerando apenas as horas de maior consumo, verifica-se que o preço é maior quando marcado pela produção hídrica, como mostra a figura 3.18.




Figura 3.18: Média do preço marginal de mercado em função da tecnologia marginal por hora
Fonte de dados: OMIE e OMIP (2021)

Quando combinadas as probabilidades de cada tipo de produção ser tecnologia marginal com os preços médios associados a essa tecnologia, verifica-se que as centrais térmicas a carvão são o tipo de produção com maior correlação com o preço *spot*, como mostra a tabela 3.1. Apesar da produção hídrica ter 51% de probabilidade de ser tecnologia marginal, a imprevisibilidade desta tecnologia quanto à capacidade de produção torna-a ligeiramente menos correlacionada com o preço.

Tabela 3.1: Relação entre o preço *spot* e o produto do preço marginal por tecnologia marginal e da probabilidade de esse tipo de produção ser tecnologia marginal
Fonte de dados: OMIE e OMIP (2021)

Tipo de produção	Hídrica	Renováveis, Cogeração e resíduos	Ciclo Combinado	Térmica convencional
Coef. <i>Pearson</i> com preço <i>spot</i> médio anual	0.92	-0.15	-0.40	0.98

A produção térmica convencional é a principal tecnologia marginal nas horas de menor consumo e a sua capacidade de produção é determinada estrategicamente (não depende de fatores externos). Logo, com base nas tecnologias marginais verificadas nos últimos anos, a produção térmica convencional é o tipo de produção mais influente no preço *spot*.

c) Potência Instalada

Para analisar a influência de cada tipo de produção na formação do preço *spot* foram observados os dados anuais da potência instalada na Península Ibérica. A figura 3.19 mostra a potência instalada por tipo de produção na Península Ibérica, em GW, de 2016 a 2020.




Figura 3.19: Potência instalada na Península Ibérica de 2016 a 2020
Fonte de dados: DGEG (2021)

A partir de 2018 verifica-se o aumento das potências instaladas das centrais por fontes de energia eólica e solar e a diminuição da potência instalada das centrais térmicas a carvão. Ou seja, a

partir de 2018 verifica-se o efeito causado pelas políticas de incentivo às energias limpas, estabelecidas pela Comissão Europeia.

Analisando a potência instalada relativa às energias renováveis em 2018 e 2020, verifica-se que a potência instalada associada a energias renováveis aumentou de 50% para 56%, como mostra a figura 3.20, em que a parte a cheio do gráfico corresponde às centrais por energias renováveis e a parte listada corresponde às centrais por energias não-renováveis.




Figura 3.20: Potência instalada na Península Ibérica por tipo de produção em 2018 e 2020
Fonte de dados: REE (2021)

As tecnologias de produção com variações mais acentuadas na sua potência instalada na Península Ibérica foram a produção por energia solar e a produção térmica a carvão. Ainda assim, os tipos de produção com maior potência instalada na Península Ibérica são a produção por energia eólica e a produção por ciclo combinado. Em 2020, estes dois tipos de produção representaram 50% da potência instalada total.

Através das análises elaboradas do consumo, do mix de produção, das tecnologias marginais e da potência instalada podem destacar-se oito variáveis com impacto no preço *spot*. Estas variáveis e o preço *spot* e as respetivas estatísticas, média, desvio padrão e taxa de variação (quociente entre o desvio padrão e a média) são apresentadas na tabela 3.2.

Tabela 3.2: Estatísticas do preço *spot* e das variáveis influentes no preço *spot*
Fonte de dados: OMIP, REE, MIBGAS

Variável		Média	Desvio padrão	$\frac{\text{Desvio padrão}}{\text{Média}}$
Preço <i>spot</i> (€/MWh)		46.23	12.34	0.27
Consumo (MWh)		679.68	40.79	0.06
Quantidade de eletricidade produzida (MWh) por	Energia hídrica	78.85	35.46	0.45
	Centrais térmicas a carvão	70.04	51.60	0.74
	Cogeração fóssil	76.44	5.01	0.07
	Ciclo combinado	95.64	45.02	0.47
	Energia eólica	137.20	39.82	0.29
Preço do gás natural (€/MWh)		17.57	6.26	0.36
Energia solar		38.92	17.50	0.45

O quociente entre o desvio padrão e a média é um indicador da volatilidade da variável. Se for necessário prever uma variável para associar ao modelo deve ter-se em conta uma variável pouco volátil para que o erro dessa previsão não seja elevado e não afete o nível de precisão do modelo. Segundo este indicador, as variáveis menos voláteis são o consumo e a quantidade de eletricidade produzida por cogeração fóssil.

3.7. Seleção do modelo

Como foi referido anteriormente, os modelos RNA com *deep learning* têm ganho mais popularidade na previsão de preços de eletricidade devido ao desenvolvimento dos algoritmos de *machine learning*. Assim, para selecionar o modelo de previsão de preços *spot* de eletricidade, foram apenas considerados modelos computacionais. No processo de seleção do modelo, os principais critérios a ter em conta foram:

- A **disponibilidade dos dados** históricos e futuros das variáveis influentes no preço;
- Os **níveis de precisão** obtidos em estudos de casos aplicados a mercados de eletricidade;
- O **horizonte temporal** utilizado em estudos de casos. Como o objetivo do modelo é obter uma previsão de médio a longo prazo, foram considerados apenas modelos do tipo *multi-step ahead*, pois este tipo de modelos permite prolongar a série da variável de saída (preço *spot*); e
- O **mercado de eletricidade** utilizado no estudo de caso pois a criticidade das variáveis influentes no preço *spot* varia de país para país (devido às diferentes condições atmosféricas e aos tipos de produção disponíveis).

Da pesquisa efetuada sobre casos de aplicação de modelos de previsão de preços de eletricidade, foi atribuída maior importância aos casos de aplicação referentes ao mercado MIBEL e aos artigos publicados nos últimos cinco anos. Entre estes destacam-se quatro modelos, todos eles aplicados ao MIBEL em 2020, onde foram comparados os níveis de precisão obtidos, as variáveis utilizadas e o horizonte temporal. A tabela 3.3 apresenta os autores, o tipo de modelo de previsão, as variáveis utilizadas, o horizonte temporal e o nível de precisão.

Tabela 3.3: Modelos aplicados à previsão de preços *spot* do MIBEL

Autores	Tipo de modelo	Variáveis	Horizonte temporal	Nível de precisão
Simón-Martín et al. (2020)	LSTM	Preço <i>spot</i> e consumo	1 semana	MAPE = 1.5 %
Simón-Martín et al. (2020)	NAR	Preço <i>spot</i>	1 semana	MAPE = 4.3 %
Simón-Martín et al. (2020)	NARX	Preço <i>spot</i> e consumo	1 semana	MAPE = 3.0 %
Monteiro et al. (2020)	RNA	Preço <i>spot</i> e preços futuros	6 meses	RMSE = 4.71 €/MWh

Cada autor determinou o nível de precisão através de diferentes indicadores: *Mean Absolute Percentage Error* (MAPE) e o *Root Mean Square Error* (RMSE). Tendo em conta que a média de preços *spot* utilizada na fase de teste do modelo RNA foi de 56.85 €/MWh, o MAPE referente à previsão do primeiro mês é 8.3% (4.71/56.85). Este valor é superior ao dos outros modelos considerados. No entanto, no nível de precisão do modelo RNA foi usado o RMSE referente à previsão do primeiro mês, pelo que os níveis de precisão não devem ser comparados pois são referentes a diferentes períodos (prolongando o horizonte temporal, o nível de precisão diminui).

Neste estudo de caso, tendo em conta os objetivos desta previsão de preços de eletricidade e os estudos de casos identificados neste contexto, o critério determinante na seleção do modelo é o horizonte temporal da previsão, sendo preferível um método adequado a previsões de médio e longo prazo. De entre os modelos identificados, o modelo RNA foi o único modelo que conseguiu resultados satisfatórios para um horizonte temporal à escala mensal. Logo, o modelo desenvolvido nesta dissertação vai ter como modelo de referência o modelo RNA.

3.8. Síntese do capítulo

Uma das medidas de redução da fatura energética da Bondalti é a implementação de um modelo de previsão de preços de eletricidade que visa auxiliar na tomada de decisões de compra de eletricidade, nomeadamente, as compras no mercado diário e no mercado de futuros.

Na fase inicial do desenvolvimento do modelo de previsão foi analisada a componente de sazonalidade do preço *spot*, a correlação entre o preço *spot* e cada uma das variáveis influentes no preço *spot*, o consumo, a evolução do mix de produção, as tecnologias marginais e a potência instalada por tecnologia. Tendo em conta cada uma destas análises, as variáveis com maior impacto nas ofertas de venda de eletricidade estão apresentadas na tabela 3.4.

Tabela 3.4: Variáveis com maior impacto nas ofertas de venda de eletricidade

Análise	Variáveis
Sazonalidade	<ul style="list-style-type: none">• Número de dias úteis por mês
Tecnologia marginal	<ul style="list-style-type: none">• Produção hídrica• Produção por ciclo combinado• Produção térmica convencional<ul style="list-style-type: none">◦ Preço dos combustíveis
Mix de produção	<ul style="list-style-type: none">• Produção eólica
Potência instalada	<ul style="list-style-type: none">• Produção eólica• Produção solar

O processo de seleção do modelo de previsão foi baseado numa pesquisa a estudos de casos de aplicação de modelos de previsão de preços de eletricidade no MIBEL, à qual foi atribuída maior importância aos casos de aplicação para previsões a médio e longo prazo. De entre os modelos analisados, o modelo RNA foi o único modelo que conseguiu resultados satisfatórios para um horizonte temporal à escala mensal.

4. Modelo de previsão de preços *spot* de eletricidade

Neste capítulo é apresentado um modelo de previsão que permite determinar a média mensal dos preços *spot* dos próximos seis meses, que pode ser utilizada como referência para a tomada de decisão de aquisição de eletricidade em qualquer tipo de contrato do mercado de futuros mensais ou no contrato trimestral de entrega no próximo trimestre ($T+1$).

Como foi referido na secção 2.5.5, os modelos computacionais, isto é, baseados em inteligência artificial, são os modelos mais bem-sucedidos neste contexto. Tendo em conta os modelos aplicados recentemente à previsão de preços *spot* neste mercado (MIBEL), o modelo de previsão apresentado nesta dissertação é baseado no modelo computacional desenvolvido por Monteiro et al. (2020) devido ao nível de precisão obtido para um horizonte temporal de seis meses. Este modelo é composto por seis Redes Neurais Artificiais (RNA) treinadas com o algoritmo Extreme Learning Machine (ELM).

Este capítulo apresenta a estrutura e o processo de desenvolvimento do modelo de previsão de preços *spot*, bem como os resultados obtidos e o impacto que as oito variáveis externas mais influentes no preço *spot* têm no nível de precisão do modelo desenvolvido.

4.1. Modelo de previsão de preços *spot* através de redes neurais artificiais

As Redes Neurais Artificiais (RNA) são sistemas baseados no sistema nervoso do ser humano, sendo compostos por um conjunto de unidades de processamento simples (células neuronais). Neste modelo, as RNA's foram treinadas com o algoritmo *Extreme Learning Machine* (ELM). ELM é um algoritmo que determina os próximos valores de uma variável através dos dados históricos dessa variável, de variáveis independentes e de uma componente aleatória.

Para desenvolver o modelo de previsão de preços *spot* através de RNA's foram utilizados dados de preços *spot* e preços futuros mensais e trimestrais de 1 de janeiro de 2016 até 31 de janeiro de 2021. As variáveis independentes utilizadas são baseadas nos preços futuros mensais relativos ao mês que se pretende e preços futuros trimestrais do trimestre onde esse mês está incluído e estão definidas na secção 2.6.

De modo a utilizar apenas os preços futuros relativos ao mês que se pretende prever, foram utilizadas seis RNA's com diferentes matrizes de entrada, uma para cada maturidade do contrato de futuros mensais. Cada RNA permite determinar a previsão para um dos seis meses seguintes.

O algoritmo ELM recebe a matriz de entrada da RNA associada à previsão do mês $M + i$, em que i pode tomar o valor 1, 2, 3, 4, 5, ou 6, o preço *spot* correspondente ao mesmo período da matriz de entrada e as matrizes aleatórias *Input Weight* e *Bias*. Por exemplo, para a previsão do mês $M+1$, a matriz de entrada é baseada nos preços futuros para o mês $M+1$ e nos preços futuros do trimestre onde este mês está incluído (T ou $T+1$), como mostra a figura 4.1.




Figura 4.1: Estrutura da RNA para a previsão dos preços do mês $M + 1$

Na figura 4.1, d representa um dia pertencente ao mês M , $x1$ representa o mês $M+1$, $x2$ representa a diferença entre o último dia antes do mês $M+1$ e o dia d , $x3$ representa a média dos preços futuros mensais para o mês $M+1$ dos últimos sete dias, $x4$ representa a média dos preços futuros trimestrais para o trimestre onde $M+1$ está incluído dos últimos 90 dias, $x5$ representa a média dos preços *spot* dos últimos sete dias e $x6$ representa a diferença entre $x3_d$ e $x3_{d-7}$.

Assim, o modelo é composto por seis RNA, todas treinadas com o algoritmo ELM (apenas diferem nas variáveis de entrada e de saída e nos parâmetros utilizados), em que cada RNA devolve a previsão para o mês $M + i$ com $i = \{1, 2, \dots, 6\}$, como mostra a figura 4.2.

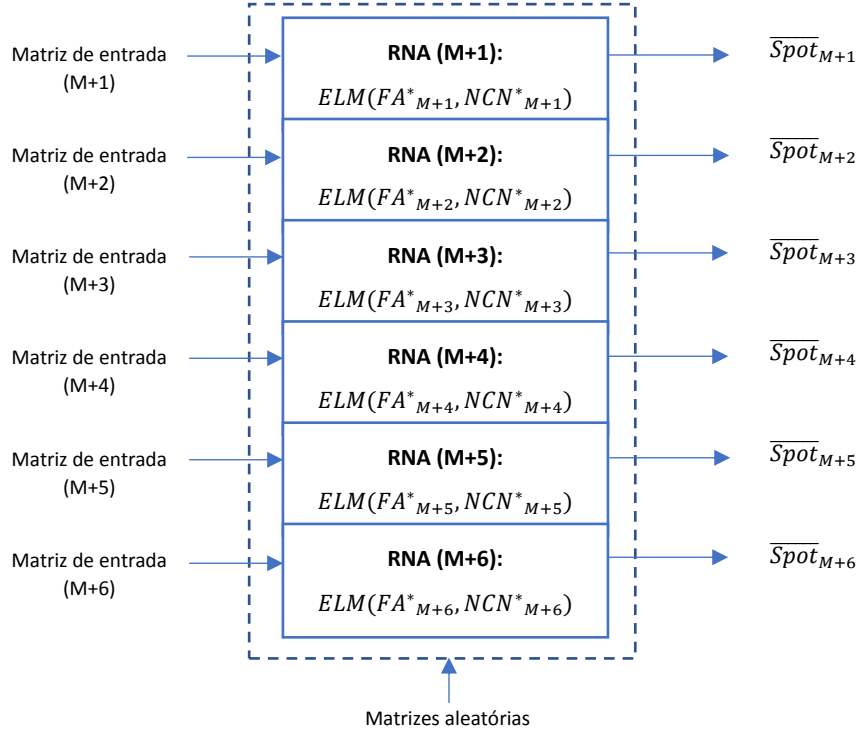


Figura 4.2: Estrutura do modelo de previsão desenvolvido

Na figura 4.2, FA^*_{M+i} representa a função de ativação ótima para a previsão do mês $M+i$, NCN^*_{M+i} representa o número de células neuronais ótimo para a previsão do mês $M+i$ e \overline{spot}_{M+i} representa a previsão para o mês $M+i$.

O processo de desenvolvimento do modelo é composto por seis etapas, nomeadamente:

- Etapla 1. Recolha e tratamento de dados;
- Etapla 2. Desenvolvimento do algoritmo;
- Etapla 3. Definição dos períodos de treino e teste;
- Etapla 4. Otimização dos parâmetros do modelo;

Etapa 5. Determinação da previsão de preços *spot*; e

Etapa 6. Determinação dos preços de referência em função do risco de compra no mercado diário.

A etapa 1 consiste na recolha de dados e tratamento dos mesmos de modo a tratar os *outliers* e construir as matrizes de entrada. O tratamento de *outliers* consiste na verificação da existência de *outliers* na série de preços *spot* correspondente ao período de treino. Os *outliers* verificados devem ser substituídos pela média do preço *spot* nesse mês, de modo a que os *outliers* não afetem o *Output Weight*.

A etapa 2 consiste na construção de um código capaz de reconhecer o mês da previsão da respetiva RNA, e assim utilizar a matriz de entrada correspondente, e reproduzir o algoritmo ELM. Para o efeito, esse código deve incluir um conjunto de funções com os seguintes objetivos:

- Receber as matrizes aleatórias e os dados das variáveis de entrada e de saída necessários para a previsão do mês $M+i$;
- Separar os valores das variáveis em dois períodos, um para a fase de treino e um para a fase de teste;
- Determinar o *Output Weight* com os valores associados ao período de treino a partir de um determinado NCN e de uma determinada função de ativação, de acordo com a equação 4;
- Determinar a previsão associada ao período de teste a partir do *Output Weight* e das variáveis de entrada correspondentes a este período; e
- Determinar o erro associado à previsão.

Na etapa 3 é definido o período de treino de forma a minimizar o erro associado à previsão. Para o efeito, a série de preços *spot* deve ser analisada e, se necessário, o algoritmo ELM deve ser aplicado com diferentes períodos de treino. Neste caso, o período de treino deve ser definido consoante os erros associados à previsão obtidos.

A etapa 4 consiste na definição do NCN e da função de ativação. Tal como na etapa 3, na etapa 4 recorre-se ao método de tentativa-erro com o objetivo de minimizar o erro associado à previsão. Após a determinação dos parâmetros ótimos, o erro da previsão do preço *spot* na fase de teste deve ser analisado, comparando os preços previstos e os preços verificados no mesmo período, de forma a determinar o nível de precisão do modelo de previsão.

Na etapa 5, as matrizes aleatórias devem ser substituídas por geradores de números aleatórios, o que provoca uma variação no *output* cada vez que se corre o algoritmo. Para determinar a previsão do preço *spot*, as fases de treino e de teste devem ser convertidas numa única fase e a previsão dos próximos seis meses deve ser obtida a partir da média de n aplicações do algoritmo usando os parâmetros ótimos.

Na etapa 6 são determinados os preços de referência para o mercado de futuros, considerando uma estratégia que visa a redução do risco de compra no mercado diário, a partir da probabilidade de a média mensal do preço *spot* ser superior ao preço futuro mensal correspondente. Esta probabilidade pode ser determinada através da variabilidade dos *outputs* obtidos com o algoritmo ELM.

4.2. Avaliação do modelo de previsão

O objetivo desta dissertação é desenvolver um modelo de previsão de preços *spot* com um erro associado inferior ao valor médio absoluto do *risk premium*, isto é, inferior à distância entre os preços futuros e a média dos preços *spot* relativa ao mesmo período de entrega. Para o efeito, para cada RNA, foram determinadas duas medidas do erro: o *Root Mean Square Error* associado ao modelo de previsão ($RMSE_{modelo, M+i}$) e o *Root Mean Square Error* associado aos preços futuros mensais ($RMSE_{futuros, M+i}$), de acordo com as equações 14 e 15.

$$RMSE_{modelo, M+i} = \sqrt{\frac{\sum_{n=1}^T (Sprevisto_{M+i} - Sreal_{M+i})^2}{T}} \quad (14)$$

$$RMSE_{futuros, M+i} = \sqrt{\frac{\sum_{n=1}^T (FMreal_{d,M+i} - Sreal_{M+i})^2}{T}} \quad (15)$$

É de referir que $Sreal_{M+i}$ representa a média dos preços *Spot* durante o mês $M+i$, $Sprevisto_{M+i}$ representa a média da estimativa dos preços *spot* durante o mês $M+i$, $FMreal_{d,M+i}$ representa o preço Futuro Mensal do dia d do mês $M+i$, e T representa o número de meses durante o período de teste.

Adicionalmente, foram determinados o erro médio da previsão, isto é, a diferença média entre o preço *spot* estimado e o preço *spot* real, e o erro médio associado aos preços futuros, a partir das equações 16 e 17, respetivamente.

$$Erro\ médio_{modelo, M+i} = \frac{\sum_{n=1}^{12} Sprevisto_{M+i} - Sreal_{M+i}}{12} \quad (16)$$

$$Erro\ médio_{futuros, M+i} = \frac{\sum_{n=1}^{12} Preços\ futuros_{M+i} - Sreal_{M+i}}{12} \quad (17)$$

O erro médio da previsão permite verificar se os erros da previsão são sistemáticos, isto é, se a estimativa é consistentemente superior ou inferior ao real.

4.3. Aplicação do modelo ao estudo de caso

4.3.1. Etapa 1. Recolha e tratamento de dados

Para desenvolver o modelo de previsão de preços *spot* foram recolhidos os dados históricos dos preços *spot* e futuros mensais e trimestrais e foram tratados os *outliers* dos preços *spot*.

Tendo em conta a sazonalidade semanal da série de preços *spot*, a verificação da existência de *Outliers* foi feita através da série das diferenças sazonais semanais. Esta série é obtida através da subtração do preço *spot* no dia t pelo preço *spot* no dia $t-7$. A série de diferenças sazonais foi normalizada através da equação 18.

$$Z_t = \frac{d_t - d}{S_d} \quad (18)$$

Na equação 18, d representa a média das diferenças sazonais (0.13) e S_d representa o desvio padrão das diferenças sazonais (8.13).

Considerou-se o pressuposto que os valores de Z_t fora do intervalo $[-3;3]$, a que corresponde um nível de confiança superior a 99%, são *outliers*. Tendo em conta este pressuposto, verificou-se que existem 25 *outliers* na série de preços *spot* entre 1 de janeiro de 2016 e 31 de dezembro de 2020 (amostra com 1834 dados). Os *outliers* foram substituídos pela média móvel centrada do preço *spot* de 28 dias. A figura 4.3 apresenta os preços *spot* reais e os preços *spot* (com tratamento dos *outliers*) entre 21 de janeiro de 2017 e 14 de fevereiro de 2017. Neste período foram identificados três *outliers* nos dias 26 e 27 de janeiro e 5 de fevereiro de 2017. Como a média móvel centrada de 28 dias não considera a sazonalidade semanal, esta componente passa a ser menos evidente após o tratamento de *outliers*, pelo que, em certas ocasiões, como a verificada no dia 5 de fevereiro de 2017, o padrão sazonal é modificado.




Figura 4.3: Preço *spot* com e sem *outliers* de 21 de janeiro de 2017 a 14 de fevereiro de 2017
Fonte de dados: OMIP (2021)

A série de preços *spot* com o tratamento dos *outliers* tem um valor médio de 46.28 €/MWh (-0.14 €/MWh ou -0.3% relativamente à série original) e um desvio-padrão de 13.65 €/MWh (-0.25 €/MWh ou -1.8% relativamente à série original).

As variáveis independentes foram agrupadas por mês de entrega e foram construídas seis matrizes de entrada, uma para cada RNA, com as variáveis definidas em 2.6.

4.3.2. Etapa 2. Desenvolvimento do algoritmo

Na etapa 2, utilizando o *software* Octave, foi construído um código com os requisitos necessários para a aplicação do algoritmo ELM, apresentados na secção 4.1. Foi desenvolvido um algoritmo capaz de utilizar uma de duas funções de ativação: função sigmoide (*sig*) e função tangente hiperbólica (*tanh*), representadas nas equações 5 e 6, respetivamente.

Quanto à componente aleatória do algoritmo, foram criadas duas matrizes aleatórias para as variáveis *Input Weight* e *Bias*. Estas matrizes são compostas por valores constantes durante o processo de desenvolvimento do modelo para permitir a comparação do RMSE com diferentes parâmetros.

Para que o algoritmo devolva o erro associado à previsão durante a fase de teste, foi implementada a função que determina o RMSE do modelo, como mostra a equação 14. Desta forma, o algoritmo ELM desenvolvido devolve a previsão do preço *spot* para o mês $M + i$ ($Sprevisto_{M+i}$), consoante a função de ativação e o NCN, e o RMSE obtido durante a fase de teste, de acordo com a equação 19.

$$[Previsão_{M+i}, RMSE_{M+i}] = ELM(M + i, \text{função de ativação}, NCN) \quad (19)$$

4.3.3. Etapa 3. Definição dos períodos de treino e de teste

Foi considerada inicialmente a hipótese de começar o período de treino no dia 1 de janeiro de 2016 (hipótese 1 ou H1). No entanto, ao verificar que os preços *spot* entre 1 de janeiro de 2016 e 30 de junho de 2016, com a exceção de cinco dias, foram inferiores à média de preços *spot*, como mostra a figura 4.4, foi considerada a hipótese de exclusão destes dados na fase de treino (hipótese 2 ou H2). A figura 4.4 apresenta também o momento em que se inicia o período de treino para ambas as hipóteses.




Figura 4.4: Preço *spot* entre 1 de janeiro de 2016 e 31 de dezembro de 2020, valor médio e data do início do período de treino para as hipóteses H1 e H2
Fonte de dados: OMIP (2021)

O algoritmo foi testado para ambas as hipóteses (com a função de ativação sigmoide e 25 células neuronais). Como o RMSE do modelo é inferior em 0.62 €/MWh relativamente à primeira hipótese, a fase de treino deve iniciar a 1 de janeiro de 2016.

Devido ao impacto que a pandemia da Covid-19 teve no mercado de eletricidade, foram considerados dois cenários (pré-pandemia e durante a pandemia) no processo de desenvolvimento do modelo, de modo a facilitar a interpretação dos resultados.

Para que seja possível analisar o erro em todos os meses do ano, o período definido para a fase de teste tem a duração de um ano e o início deste período depende do cenário considerado (pré-pandemia ou durante a pandemia). No cenário pré-pandemia, o período de teste inicia a 1 de fevereiro de 2019 e termina a 31 de janeiro de 2020. No cenário de pandemia, o período de teste inicia a 1 de fevereiro de 2020 e termina a 31 de janeiro de 2021.

4.3.4. Etapa 4. Otimização dos parâmetros do modelo

a) Número de células neuronais e função de ativação

Na etapa de otimização dos parâmetros, o modelo foi testado para cada RNA com diferentes NCN, desde 5 a 500 células neuronais, e duas funções de ativação: função sigmoide (sig) e função tangente hiperbólica (tanh).

Os parâmetros de cada RNA foram definidos de forma a minimizar o RMSE do modelo. Por exemplo, para a previsão dos preços *spot* do mês $M+1$, os RMSE's obtidos com a função de ativação tangente hiperbólica e com a função de ativação sigmoide estão apresentados nas figuras 4.5 e 4.6, respetivamente.




Figura 4.5: RMSE usando a função de ativação tangente hiperbólica para a previsão do preço *spot* do mês $M + 1$




Figura 4.6: RMSE usando a função de ativação sigmoide para a previsão do preço *spot* do mês $M + 1$

Com base nos RMSE's obtidos nesta RNA, constata-se que o menor valor do RMSE (5.67 €/MWh) foi obtido com a função tangente hiperbólica e 55 células neuronais. Este procedimento foi aplicado às outras cinco RNA. Os NCN's ótimos por função de ativação e respectivos RMSE's para cada cenário podem ser consultados na tabela 4.1.

Tabela 4.1 NCN's ótimos por função de ativação e RNA e respectivos RMSE's

		Função de ativação	Cenário			
			Pré-pandemia		Durante a pandemia	
			NCN	RMSE (€/MWh)	NCN	RMSE (€/MWh)
RNA	M+1	sig	110	6.81	65	8.18
		tanh	55	5.24	105	6.34
	M+2	sig	425	5.11	365	12.18
		tanh	45	6.01	315	8.44
	M+3	sig	435	7.49	265	10.59
		tanh	5	9.72	85	10.01
	M+4	sig	335	8.74	175	15.57
		tanh	15	8.98	55	12.92
	M+5	sig	5	10.49	5	15.64
		tanh	5	10.53	25	15.58
	M+6	sig	5	10.39	135	14.79
		tanh	5	10.78	5	15.01

Com base nos RMSE's obtidos nesta etapa, foram definidos os parâmetros ótimos do modelo para cada um dos cenários considerados, apresentados na tabela 4.2.

Tabela 4.2: Parâmetros ótimos de cada RNA

Cenário	RNA	M+1	M+2	M+3	M+4	M+5	M+6
Pré-pandemia	Função de ativação	tanh	sig	sig	sig	sig	sig
	NCN	55	425	435	335	5	5
Durante a pandemia	Função de ativação	tanh	tanh	tanh	tanh	tanh	sig
	NCN	105	315	85	55	25	135

Verifica-se que os parâmetros ótimos variam consoante o cenário e o horizonte temporal da previsão. A variabilidade dos parâmetros ótimos entre cenários indica que o modelo de previsão deve ser monitorizado várias vezes ao longo do ano. Ou seja, para manter os níveis de precisão semelhantes aos obtidos é necessário reavaliar os parâmetros do modelo pelo menos semestralmente. Ambas as funções de ativação devem ser consideradas no processo de reavaliação dos parâmetros.

Usando os parâmetros ótimos, foram determinadas as previsões para o período de teste com cada uma das seis RNA's.

b) Previsões para o período de teste. Cenário pré-pandemia

As previsões para o mês M+1 e para o mês M+6 obtidas na fase de teste no cenário pré-pandemia, os respectivos valores reais do preço *spot* e os preços futuros para o mesmo período são apresentados nas figuras 4.7 e 4.8. As previsões obtidas na fase de teste a partir das restantes RNA's podem ser consultadas no anexo I.




Figura 4.7: Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados da RNA M+1 e preços futuros M+1 (cenário pré-pandemia)




Figura 4.8: Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados da RNA M+6 e preços futuros M+6 (cenário pré-pandemia)

De um modo geral, verificou-se uma descida no preço *spot* ao longo do período de teste do cenário de pré-pandemia. Essa descida foi modelada nas previsões para o mês M+1. Nas previsões para o mês M+6, os valores previstos são superiores aos valores reais, resultado do elevado *risk premium* verificado, isto é, a diferença entre a média dos preços *spot* e os preços futuros relativos ao mesmo período de entrega.

No cenário de pré-pandemia, o mês em que foi obtido um maior erro de precisão para o mês seguinte foi o mês de dezembro de 2019 ($RMSE_{M+1} = 13.98 \text{ €/MWh}$ e $RMSE_{M+6} = 19.33 \text{ €/MWh}$).

Segundo o boletim climatológico elaborado pelo Instituto Português do Mar e da Atmosfera (IPMA, 2020), durante este mês “verificaram-se vários episódios de precipitação intensa associada à passagem das tempestades Daniel, Elsa e Fabien”.

Adicionalmente, a tempestade Elsa provocou também um aumento súbito na intensidade do vento, que resultou num aumento da produção eólica. Esta combinação de fatores externos provocou uma descida no preço *spot* nos dias associados às tempestades que não foi considerada na formação de preços futuros.

c) Previsões para o período de teste. Cenário pandemia

As previsões para o mês M+1 e para o mês M+6 obtidas na fase de teste no cenário pandemia, os respetivos valores reais do preço *spot* e os preços futuros para o mesmo período são apresentados nas figuras 4.9 e 4.10. As previsões obtidas na fase de teste a partir das restantes RNA's podem ser consultadas no anexo II.




Figura 4.9: Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados da RNA M+1 e preços futuros M+1 (cenário de pandemia)




Figura 4.10: Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados da RNA M+6 e preços futuros M+6 (cenário de pandemia)

Durante o período de teste do cenário de pandemia, em termos médios, o preço *spot* foi inferior relativamente ao período de teste do cenário de pré-pandemia, resultado de uma acentuada descida do preço *spot* entre fevereiro e abril de 2020. O *risk premium* mais elevado ocorreu precisamente no mês de abril de 2020, mês em que o preço *spot* atingiu os valores mais reduzidos e o RMSE atingiu valores máximos ($RMSE_{M+1} = 13.96 \text{ €/MWh}$ e $RMSE_{M+6} = 35.63 \text{ €/MWh}$). Neste mês verificou-se

uma súbita descida nos valores do consumo e do preço do gás natural, que atingiram os valores mínimos de 473 MWh e 5.69 €/MWh, respetivamente, que justificam este erro.

d) Precisão do modelo no período de teste

As previsões do preço *spot* para os seis meses seguintes obtidas na fase de teste usando os parâmetros ótimos foram comparadas aos valores reais e foram determinados os RMSE's. A precisão do modelo de previsão, definida com base no RMSE, foi comparada com a precisão associada aos preços futuros, determinados de acordo com a equação 14. Uma análise comparativa semelhante foi feita com base nos erros médios do modelo e os erros médios dos preços futuros, isto é, o *risk premium* médio, determinados através das equações 16 e 17, respetivamente. As medidas de erro determinadas são apresentadas na tabela 4.3.

Tabela 4.3: RMSE's e erros médios da previsão do preço *spot* do modelo e dos preços futuros obtidos na fase de teste

		RNA						Média
		M+1	M+2	M+3	M+4	M+5	M+6	
Pré-pandemia	RMSE _{modelo} (€/MWh)	5.24	5.11	7.49	8.74	10.49	10.39	7.91
	RMSE _{futuros} (€/MWh)	6.87	10.11	12.00	12.81	14.57	15.23	11.93
	Erro médio modelo (€/MWh)	3.41	2.53	2.16	5.68	8.98	8.64	5.23
	Erro médio futuros (€/MWh)	4.65	7.69	9.91	10.92	12.67	13.42	9.88
Pandemia	RMSE _{modelo} (€/MWh)	6.38	8.44	10.01	12.92	15.58	14.79	11.35
	RMSE _{futuros} (€/MWh)	5.83	8.96	11.48	13.40	16.28	18.29	12.37
	Erro médio modelo (€/MWh)	2.50	2.87	3.79	7.93	12.01	8.56	6.28
	Erro médio futuros (€/MWh)	1.21	2.95	4.51	6.34	8.32	10.03	5.56

. Em ambos os cenários, o RMSE aumenta com o horizonte da previsão, isto é, com o período entre o mês corrente e o mês da previsão, pois existe uma maior incerteza associada às previsões de médio prazo e a relação entre preços *spot* e preços futuros é mais evidente nos contratos de menor maturidade.

Os RMSE's obtidos, com exceção da previsão para o mês seguinte (M+1) durante a pandemia, foram inferiores aos RMSE's associados aos preços futuros. Em termos médios, o RMSE do modelo de 7.91 €/MWh no cenário de pré-pandemia (-4,02 €/MWh relativamente ao RMSE associado aos preços futuros) e de 11.35 €/MWh no cenário de pandemia (-1,02 €/MWh relativamente ao RMSE associado aos preços futuros).

Os resultados da avaliação do modelo de previsão obtidos demonstram que a previsão de preços *spot* foi mais próxima do preço *spot* verificado do que os preços futuros. Logo, o modelo de previsão desenvolvido permite obter uma precisão superior a uma previsão baseada apenas nos valores atuais dos preços futuros.

O erro médio associado aos preços futuros é positivo em todas as RNA e cenários, o que indica que o preço *spot* é geralmente inferior aos preços futuros. Como o modelo utiliza preços futuros para prever o preço *spot*, o erro médio do modelo também é positivo em todas as RNA e cenários. Logo, os preços *spot* estimados tendem a ser superiores aos preços *spot* reais. Esta medida de erro, tal como o RMSE, também tende a aumentar com o horizonte da previsão.

Considerando apenas o mercado diário e o mercado de futuros, se as decisões de compra de eletricidade durante o período de teste tivessem sido baseadas exclusivamente nos preços *spot* previstos obtidos com o modelo desenvolvido, 68.7% das decisões resultariam na compra de eletricidade ao melhor preço, como mostra a tabela 4.4.

Tabela 4.4: Percentagem das decisões de compra ao melhor preço

Cenário	RNA						Média
	M+1	M+2	M+3	M+4	M+5	M+6	
Pré-pandemia	72.5%	71.7%	90.8%	93.3%	67.1%	56.7%	75.4%
Pandemia	52.9%	43.8%	86.3%	49.2%	60.4%	78.8%	61.9%
							68.7%

De acordo com as percentagens das decisões de compra ao melhor preço, verifica-se também que o modelo de previsão de preços *spot* teria obtido maior eficácia no cenário de pré-pandemia (75.4%).

4.3.5. Etapa 5. Determinação da previsão dos preços *spot*

Para determinar uma previsão, as matrizes de entrada devem ser atualizadas, sendo que a fase de treino deve terminar no dia anterior ao dia da previsão. A previsão para o mês $M + i$ é obtida através do produto entre os valores da última linha da matriz de entrada correspondente ao mês $M + i$ e o respetivo *Output Weight* determinado na fase de treino. O algoritmo tem assim em consideração os preços futuros estabelecidos no próprio dia, o que permite modelar a evolução diária dos preços futuros.

O conjunto dos períodos de treino e de teste passou a constituir um único período de treino, de 1 de janeiro de 2016 a 20 de dezembro de 2020, e a previsão foi determinada com base nas variáveis de entrada do dia 21 de dezembro de 2020. As matrizes aleatórias foram substituídas por geradores de números aleatórios e foram utilizados os parâmetros ótimos do cenário de pandemia para determinar a previsão ao longo do primeiro semestre de 2021. Para o efeito, o algoritmo foi aplicado 100 vezes e a previsão da média mensal do preço *spot*, apresentada na figura 4.11, foi determinada a partir da média dos valores obtidos em cada aplicação do algoritmo.




Figura 4.11: Previsão da média mensal do preço *spot* para o primeiro semestre de 2021

Os resultados evidenciam uma súbita descida do preço *spot* entre os meses de janeiro e fevereiro de 2021. De acordo com a análise à série de preços *spot* apresentada na secção 3.5, a variabilidade dos preços *spot* tende a aumentar no início e no fim de cada ano, que justificam a variação entre os dois primeiros meses. De acordo com a mesma análise, o preço *spot* tende a aumentar a partir de

maio. Essa tendência é verificada com a previsão obtida, em que se verifica uma ligeira subida no preço *spot* entre maio e junho de 2021.

4.3.6. Etapa 6. Determinação dos preços de referência em função do risco de compra no mercado diário

O objetivo deste modelo é prestar auxílio no processo de tomada de decisão no que diz respeito à aquisição de eletricidade nos mercados futuros mensais ao determinar, de entre o mercado diário e o mercado de futuros, qual o mercado de eletricidade com o preço mais baixo. De acordo com a avaliação do modelo, apresentada na secção 4.3.4, o processo de tomada de decisões torna-se mais eficiente usando as previsões do preço *spot* obtidas com o modelo desenvolvido.

No entanto, devido à elevada volatilidade dos preços *spot*, a compra no mercado diário está sujeita a uma elevada e repentina subida de preço. Assim, para além dos preços *spot* previstos, o risco de compra no mercado diário (preços *spot*) também deve ser considerado na tomada de decisões de compra de eletricidade. Tendo em conta uma estratégia que visa a redução do risco de compra no mercado diário, a eletricidade deve ser adquirida no mercado de futuros mesmo a um preço ligeiramente superior ao preço *spot* previsto, de modo a diminuir o risco de compra no mercado diário.

Neste trabalho, o conceito de risco de compra no mercado diário é definido como a probabilidade de a média mensal do preço *spot* ser superior ao preço futuro mensal correspondente.

Caso o risco de compra no mercado diário seja inferior a 50%, então existe maior probabilidade de o mercado diário dispor do preço mais baixo para o mês em análise. No entanto, tendo em conta a estratégia de compra que visa a redução do risco de compra no mercado diário, esta condição é insuficiente para a tomada de decisão de compra pois o risco de compra no mercado diário pode atingir valores próximos dos 50%.

Com base no conjunto de *outputs* obtido a partir do algoritmo ELM é possível determinar o risco de compra no mercado diário através da frequência de *outputs* com valores superiores ao preço atual do mercado de futuros. Como o algoritmo ELM inclui geradores de números aleatórios, o *output* varia cada vez que o algoritmo é aplicado. Assim, é possível obter um conjunto de *outputs* para o mesmo mês de entrega.

Por exemplo, o conjunto de *outputs* obtidos no dia 21 de dezembro de 2020 para a previsão do mês de maio de 2021 (M+4) é apresentado no histograma da figura 4.12, bem como o preço para o mesmo mês no mercado de futuros estabelecido nesse dia.




Figura 4.12: Preços *spot* estimados e preço futuro para maio de 2021 (com base nos dados históricos até dia 20 de dezembro de 2020)

No exemplo da figura 4.12, o risco de compra no mercado diário é de 53%, determinado a partir do quociente entre o número de *outputs* com valores superiores ao preço futuro e o número total de *outputs* (53/100).

Como o risco é superior a 50%, então existe maior probabilidade de o mercado de futuros dispor do preço mais baixo para o mês em análise. Devido ao elevado risco de compra no mercado diário obtido para o mês em análise, a eletricidade deve ser adquirida no mercado de futuros.

Como os preços futuros são atualizados todos os dias, uma possível estratégia de compra de eletricidade no mercado de futuros consiste em determinar um preço de referência com base num determinado risco (α) previamente estabelecido. Assumindo que os *outputs* do modelo têm um comportamento que está de acordo com uma distribuição normal, o preço de referência para o mês de entrega $M + i$ pode ser determinado através da equação 20.

$$\text{preço referência}_{M+i} = Z_{\alpha} \cdot S_{Sprevisto,M+i} + \overline{Sprevisto}_{M+i} \quad (20)$$

Na equação 20, Z_{α} representa o valor normalizado associado ao risco α , $S_{Sprevisto,ME}$ representa o desvio padrão do *output* correspondente à previsão do preço *spot* para o mês $M + i$ e $Sprevisto_{M+i}$ representa a previsão do preço *spot* para o mês $M + i$. Para o mês de maio de 2021, os preços referência em função do risco de compra no mercado de futuros são apresentados na figura 4.13.




Figura 4.13: Preços de referência em função do risco de compra no mercado diário

A partir das aplicações do algoritmo para a previsão de preços *spot* para maio de 2021, verifica-se que, para um nível de confiança de 95%, o preço *spot* está contido num intervalo entre 37.64 €/MWh e 51.15 €/MWh.

Para maio de 2021, admitindo um risco de compra no mercado diário de 40%, a eletricidade deve ser adquirida no mercado de futuros se os preços neste mercado não ultrapassarem o valor de 45.43 €/MWh (preço de referência), pois o preço no mercado diário pode atingir valores até 51.15 €/MWh para um nível de confiança de 95%.

Admitindo o mesmo risco de compra no mercado diário (40%), os preços de referência obtidos para o horizonte da previsão obtida na secção 4.3.5 são apresentados na tabela 4.5, bem como os preços futuros e preços *spot* previstos para o mesmo período.

Tabela 4.5: Preços futuros, preços *spot* previstos e preços de referência para o primeiro semestre de 2021

	janeiro	fevereiro	março	abril	maio	junho	
Preço futuro	52,58	54,04	44,14	42,55	43,57	45,89	€/MWh
Preço <i>spot</i> previsto	52,21	37,56	44,02	41,09	44,39	45,13	€/MWh
Preço de referência (risco de 40%)	53,21	38,50	45,19	42,26	45,43	46,34	€/MWh

Com base nos resultados apresentados na tabela 4.5, a eletricidade deve ser adquirida no mercado de futuros com a exceção dos meses de fevereiro e de abril de 2021.

4.4. Impacto das variáveis influentes no preço *spot*

De forma a identificar oportunidades de melhoria no modelo desenvolvido, foi feita uma análise do modelo utilizando as oito variáveis externas mais influentes no preço *spot*, nomeadamente:

- Consumo de eletricidade;
- Preço do gás natural;
- Quantidade de eletricidade produzida a carvão;
- Quantidade de eletricidade produzida por ciclo combinado;
- Quantidade de eletricidade produzida por cogeração fóssil;
- Quantidade de eletricidade produzida a partir de energia eólica;
- Quantidade de eletricidade produzida a partir de energia solar; e
- Quantidade de eletricidade produzida a partir de energia hídrica.

Esta análise permite determinar o impacto de cada variável numa previsão de preços *spot* obtida com base nos preços futuros e quais os próximos passos a dar para aumentar o nível de precisão do modelo desenvolvido.

De forma a determinar quais as variáveis que podem melhorar a precisão do modelo, foi adicionada uma sétima variável e foi determinada a previsão do preço *spot*. Para isso, o algoritmo ELM foi desenvolvido usando uma nova matriz de entrada composta por sete variáveis: as seis variáveis iniciais e uma das oito variáveis externas mais influentes no preço *spot*.

Para as RNA's das previsões M+1 e M+6 de ambos os cenários, os parâmetros foram otimizados com as novas matrizes de entrada (segundo os procedimentos descritos na secção 4.3.4) e foi determinado o nível de precisão a partir do inverso do RMSE obtido durante a fase de teste para facilitar a interpretação dos resultados. Os níveis de precisão obtidos em cada cenário são apresentados nas figuras 4.14 e 4.15, para previsões do mês M+1 e do mês M+6.




Figura 4.14: Precisão das previsões do preço *spot* para o mês M+1




Figura 4.15: Precisão para previsões do preço *spot* para o mês M+6

a) Mês M+1

No cenário de pré-pandemia, as variáveis que aumentaram o nível de precisão da previsão para o mês M+1 foram duas, a quantidade de eletricidade produzida a partir de energia solar, devido à implementação de novas centrais solares fotovoltaicas, e o preço do gás natural, que é responsável por uma parte importante do custo neste mercado.

No cenário de pandemia, as variáveis que aumentaram o nível de precisão foram quatro, a quantidade produzida por combustíveis fósseis, o preço do gás natural e as quantidades de eletricidade produzida a partir de energias eólica e solar.

De acordo com a evolução da potência instalada entre 2016 e 2020, apresentada na secção 3.6.2, verificou-se que, a partir de 2018, a potência instalada das tecnologias das energias eólica e solar aumentou, enquanto a potência instalada da produção a carvão diminuiu.

Em ambos os cenários, verifica-se que as variáveis com maior impacto na previsão de preços *spot* estão relacionadas com a variação da potência instalada pois os tipos de produção onde existiram variações na potência instalada durante estes períodos foram a produção eólica, a produção solar e a produção a carvão. Logo, a evolução da potência instalada deve ser analisada de forma a complementar a previsão obtida com o modelo desenvolvido.

b) Mês M+6

No cenário de pré-pandemia, as variáveis que aumentaram o nível de precisão da previsão para o mês M+6 foram quatro, as quantidades de eletricidade produzida a partir de energias hídrica, eólica, por cogeração fóssil e por centrais a carvão.

No cenário de pandemia, todas as variáveis testadas aumentaram o nível de precisão da previsão para o mês M+6 pois verificou-se um maior desvio entre os preços futuros e os preços *spot* neste período, especialmente entre os preços *spot* verificados em abril e maio de 2021 e os preços futuros formados no fim do ano de 2019 para o mesmo período de entrega, como foi verificado na secção 4.3.4.

Em ambos os cenários, a quantidade produzida a partir de energia hídrica foi a variável com maior impacto positivo na precisão da previsão para o mês M+6 por ser a tecnologia que mais vezes marca o preço (tecnologia marginal). Logo, a evolução da produção hídrica deve ser analisada de forma a complementar a previsão obtida com o modelo desenvolvido. No entanto, existe uma elevada volatilidade associada aos preços marcados por esta tecnologia, como mostra a análise aos preços marginais de mercado por tecnologia marginal, apresentada no capítulo 3.6.2.

Apesar de todas as variáveis testadas influenciarem o preço *spot*, algumas destas variáveis têm um forte impacto na formação dos preços futuros, pelo que não acrescentam valor ao modelo desenvolvido, o que se verifica com o consumo. Ou seja, as ofertas de compra e venda no mercado de futuros dependem do consumo previsto.

4.5. Síntese do capítulo

No presente capítulo, foi apresentado o modelo de previsão de preços *spot* desenvolvido, a aplicação do modelo ao estudo de caso e a avaliação do modelo com base nos resultados obtidos.

Para estimar os preços *spot* num horizonte de médio prazo, foi desenvolvido um modelo de previsão de preços *spot* através de redes neuronais artificiais, cujo processo de desenvolvimento visa a redução do erro associado à previsão, nomeadamente o RMSE do modelo. O processo de desenvolvimento, constituído por seis etapas, foi aplicado a dois cenários, pré-pandemia e durante a pandemia, de modo a facilitar a interpretação dos resultados.

Na primeira etapa, foram recolhidos e tratados os dados dos preços *spot* e dos preços futuros.

Na segunda etapa, foi criado um código com o algoritmo ELM, que determina os preços *spot* previstos e o RMSE do modelo.

Na terceira etapa, foram definidos os períodos de treino e de teste do algoritmo ELM para cada cenário. Nesta etapa, verificou-se que é necessário reavaliar os parâmetros do modelo pelo menos semestralmente devido à variabilidade dos parâmetros ótimos obtidos.

Na quarta etapa, foram definidos os parâmetros ótimos do algoritmo e determinados os níveis de precisão com base nos períodos de teste de ambos os cenários. Nesta etapa, verificou-se que a previsão de preços *spot* foi mais próxima do preço *spot* verificado do que os preços futuros.

Na quinta etapa, as matrizes aleatórias foram substituídas por geradores de números aleatórios e foi determinada a previsão do preço *spot* para o primeiro semestre de 2021.

Na sexta etapa, foram determinados os preços de referência para o mercado de futuros, que permitem prestar auxílio nas tomadas de decisão de compra tendo em conta o risco de compra no mercado diário.

Por fim, foi analisado o impacto que variáveis externas têm no nível de precisão do modelo desenvolvido. Verificou-se que o nível de precisão para as previsões para o mês M+1 foi afetado pela evolução da potência instalada, enquanto que para as previsões para o mês M+6, o nível de precisão aumentou com a inclusão dos dados da quantidade de eletricidade produzida a partir da energia hídrica.

5. Conclusões

Nesta dissertação foi desenvolvido um modelo de previsão de preços *spot* de eletricidade com o objetivo de prestar auxílio no processo de tomada de decisão no que diz respeito à aquisição de eletricidade nos mercados futuros mensais. Através de redes neurais artificiais, foi desenvolvido um algoritmo que determina a média do preço *spot* para os próximos seis meses.

Para além de determinar a previsão do preço *spot*, o modelo desenvolvido também permite determinar o preço de referência associado a um determinado risco de compra no mercado diário.

5.1. Resultados

A precisão do modelo desenvolvido foi avaliada através de duas medidas de erro: *Root Mean Square Error* (RMSE) e o erro médio. Através do RMSE, verificou-se que o erro associado à previsão, que varia entre 5.11 €/MWh e 15.58 €/MWh, é normalmente inferior ao módulo da diferença entre preços futuros e preços *spot* para o mesmo período de entrega.

Quanto ao erro médio, que varia entre 2.16 €/MWh e 12.01 €/MWh, verificou-se que os preços previstos são normalmente superiores aos preços reais. Estes resultados incluem previsões no cenário da pandemia da covid-19, em que se verificou uma maior incerteza nas previsões.

Com base nos resultados obtidos na fase de teste, verificou-se ainda que, se as decisões de compra de eletricidade durante o período de teste tivessem sido baseadas exclusivamente nos preços *spot* previstos obtidos com o modelo desenvolvido, 68.7% das decisões resultariam na compra de eletricidade ao melhor preço.

Com base na etapa de otimização dos parâmetros do modelo, verificou-se uma enorme variabilidade nos parâmetros ótimos em função do horizonte da previsão e do cenário considerado, pelo que o modelo de previsão desenvolvido deve ser monitorizado várias vezes ao longo do ano para manter os níveis de precisão semelhantes aos obtidos.

Através da análise do impacto das variáveis influentes no preço *spot*, verificou-se que o nível de precisão para as previsões para o mês M+1 durante a fase de teste foi afetado pela evolução da potência instalada. Quanto ao nível de precisão das previsões para o mês M+6, durante a fase de teste o nível de precisão aumentou com a inclusão dos dados da quantidade de eletricidade produzida a partir da energia hídrica, pelo que a previsão desta variável pode aumentar o nível de precisão do modelo desenvolvido.

Assim, devido à enorme volatilidade dos preços *spot* e às constantes alterações neste mercado, apesar de o modelo explicar parte da série de preços *spot*, é importante analisar frequentemente a evolução do mercado, sobretudo as alterações na potência instalada, o impacto da produção hídrica na formação dos preços *spot* e a evolução do preço do gás natural e do mercado de licenças de emissões de carbono.

5.2. Limitações

O horizonte temporal deste modelo é limitado pela maturidade máxima dos contratos de aquisição de eletricidade no mercado de futuros mensais. Isto é, como o modelo utiliza os preços

futuros mensais para obter a previsão do preço *spot* nesse mesmo período de entrega, o horizonte temporal da previsão só pode ser prolongado até ao mês de entrega do último contrato do mercado de futuros mensais (M+6).

Uma solução possível para prolongar o horizonte temporal é substituir os preços futuros mensais por preços futuros anuais. No entanto, não existem estudos que demonstrem que existe uma associação significativa entre preços *spot* e preços futuros anuais.

5.3. Trabalhos futuros

Tendo em conta a complexidade do mercado de eletricidade e o interesse económico gerado neste mercado, a previsão de preços *spot* é uma ferramenta com várias oportunidades de melhoria. Mais concretamente, os trabalhos futuros sugeridos são os seguintes:

- **Aplicação do modelo ajustado às previsões de longo prazo**, utilizando os preços futuros trimestrais e anuais enquanto variáveis de entrada para prolongar o horizonte temporal da previsão para dois anos;
- **Análise aos preços dos combustíveis e às tendências destes mercados**, incluindo os preços das licenças de emissão de carbono e as quantidades de carbono emitidas por tipo de produção; e
- **Aplicação de um modelo ajustado à previsão do preço do gás natural na Península Ibérica.**

Bibliografia

- Aggarwal, S.; Saini, L.; Kumar, A. (2009). Electricity price forecasting in deregulated markets: A review and evaluation. *International Journal of Electrical Power & Energy Systems*, 31, 13–22. <https://doi.org/10.1016/j.ijepes.2008.09.003>
- Autoridade da Concorrência (2009). *Relatório sobre a formação dos preços grossistas da energia eléctrica em Portugal no segundo semestre de 2007*. Lisboa. http://www.concorrencia.pt/SiteCollectionDocuments/Estudos_e_Publicacoes/Energia_e_Com bustiveis/03_Relatorio_Mercado_Grossista_Energia.pdf. Acedido a 14 abril 2021.
- Bessembinder, H.; Lemmon, M.L. (2002). Equilibrium pricing and optimal hedging in electricity forward markets. *The Journal of Finance*, 57, 1347–1382. <https://doi.org/10.1111/1540-6261.00463>
- Bre, F.; Gimenez, J. M.; Fachinotti, V. D. (2018). Prediction of wind pressure coefficients on building surfaces using artificial neural networks. *Energy and Buildings*, 158, 1429–1441. <https://doi.org/10.1016/j.enbuild.2017.11.045>
- Billingsley, P. *Probability and Measure*. 1st Edition. Nova Iorque: Wiley, 1995.
- Carmona, R; Coulon, M. (2014). A Survey of Commodity Markets and Structural Models for Electricity Prices. In: Benth, Fred Espen, Kholodnyi, Valery A and Laurence, Peter (Eds.). *Quantitative energy finance: modeling, pricing, and hedging in energy and commodity markets*. (1st Edition, 41-83). Springer-Verlag, New York. https://doi.org/10.1007/978-1-4614-7248-3_2
- Cartea, A.; Villaplana, P. (2014). An analysis of the main determinants of electricity forward prices and forward risk Premia. In: Benth, Fred Espen, Kholodnyi, Valery A and Laurence, Peter (Eds.). *Quantitative energy finance: modeling, pricing, and hedging in energy and commodity markets*. (1st Edition, 215–236). Springer-Verlag, New York. <http://dx.doi.org/10.2139/ssrn.2142590>
- Chapagain, K.; Sato, T.; Kittipiyakul, S. (2017). Performance analysis of short-term electricity demand with meteorological parameters. In: 2017 14th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON). Presented at the 2017 14th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON), 330–333. <https://doi.org/10.1109/ECTICon.2017.8096240>
- Conselho de Reguladores do MIBEL (2009). *Descrição do funcionamento do MIBEL*. Lisboa, https://www.dgeg.gov.pt/media/3o1fx40/descricao_funcionamento_mibel_marco_2009.pdf Acedido a 14 abril 2021.
- Da Silva, R.R.; Dias, M.F.; Madaleno, M. (2019). Iberian electricity market spot and futures prices: Comovement and lead-lag relationship analysis. *International Journal of Sustainable Energy Planning and Management*, 19, 59–68. doi:10.5278/ijsepm.2019.19.6
- Decreto Lei no 38/2013 de 15 de março do Ministério da Agricultura, do Mar, do Ambiente e do Ordenamento do Território. Diário da República: I série, Nº 53 (2013). Acedido a 13 maio 2021. Disponível em www.dre.pt.
- ERSE (2013). *Manual de Procedimentos da Gestão Global do Sistema do Setor Elétrico*. Lisboa. https://www.mercado.ren.pt/EN/Electr/MarketInfo/Document/BibSubregula/MP_GGS_SE.pdf. Acedido a 14 abril 2021.

- ERSE (2018). *Relatório anual sobre os mercados de eletricidade e de gás natural em 2017*. Lisboa, p. 58, https://www.ceer.eu/documents/104400/6319351/C18_NR_Portugal-NL.pdf/b1eaf485-50b9-aa92-4e11-12b9a37d6e23. Acedido a 14 abril 2021.
- Erbach G. (2016). Understanding electricity markets in the EU. 10. *European Parliamentary Research Service*. [https://www.europarl.europa.eu/RegData/etudes/BRIE/2016/593519/EPRS_BRI\(2016\)593519_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/BRIE/2016/593519/EPRS_BRI(2016)593519_EN.pdf). Acedido a 14 abril 2021.
- Gallego, C. J. (2012). Entiende el mercado eléctrico. [S.l.]: El Observatorio Crítico de la Energía.
- Galp Power (2006). *Estudo de Impacte Ambiental Resumo Não Técnico*, Lisboa. <https://siaia.apambiente.pt/AIADOC/AIA1519/RNT1519.pdf>. Acedido a 14 abril 2021.
- Girish, G.P.; Murthy, P.; Sedidi, V.; Panda, A.; Rath B.N. (2014). Forecasting Electricity Prices in Deregulated Wholesale Spot Electricity Market: A Review, *International Journal of Energy Economics and Policy*, 4, 32-42
- Hess, M. (2017). Modeling positive electricity prices with arithmetic jump-diffusions. *Energy Economics* 67, 496–507. <https://doi.org/10.1016/j.eneco.2017.08.016>
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. 2nd Edition, Prentice Hall, Englewood Cliffs, NJ.
- Hong, T.; Pinson, P.; Fan, S.; Zareipour, H.; Troccoli, A.; Hyndman, R.J. (2016). Probabilistic energy forecasting: Global energy forecasting competition 2014 and beyond. *Int. J. Forecast.*, 32, 896–913. <https://doi.org/10.1016/j.ijforecast.2016.02.001>
- Hoshmand, A.R. (2010). *Business forecasting: a practical approach*, 2nd Edition. Routledge, New York.
- Hull, J. *Options, Futures, and Other Derivatives*, 9th Edition. Prentice Hall: Upper Saddle River, NJ, USA, 2015.
- IPMA (2020), *Boletim Climatológico, Dezembro 2019*. Lisboa. https://www.ipma.pt/resources.www/docs/im.publicacoes/edicoes.online/20200123/gUybHojZlxtWdawgmvjf/cli_20191201_20191231_pcl_mm_co_pt.pdf. Acedido a 14 abril 2021
- Kanamura, T.; Ōhashi, K. (2007). A structural model for electricity prices with spikes: Measurement of spike risk and optimal policies for hydropower plant operation. *Energy Economics*, 29, 1010–1032. <https://doi.org/10.1016/j.eneco.2006.05.012>
- Lago, J.; De Ridder, F.; De Schutter, B. (2018). Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms. *Applied Energy*, 221, 386–405. <https://doi.org/10.1016/j.apenergy.2018.02.069>.
- Marcjasz, G. (2020). Forecasting Electricity Prices Using Deep Neural Networks: A Robust Tanher-Parameter Selection Scheme. *Energies* 2020, 13(18). <https://doi.org/10.3390/en13184605>
- Monteiro, C.; Fernandez-Jimenez, L. A.; Ramirez-Rosado, I. J. (2020). Predictive Trading Strategy for Physical Electricity Futures. *Energies*, 13(14), 35-55. doi:10.3390/en13143555
- Mureddu, M.; Meyer-Ortmanns, H. (2018). Extreme prices in electricity balancing markets from an approach of statistical physics. *Physica A: Statistical Mechanics and its Applications* 490, 1324–1334. <https://doi.org/10.1016/j.physa.2017.09.001>

- Narajewski, M.; Ziel, F. (2020). Ensemble forecasting for intraday electricity prices: Simulating trajectories. *Applied Energy*, 279, Article 115801.
<https://doi.org/10.1016/j.apenergy.2020.115801>
- Simón-Martín, M. de; Bracco, S.; Rosales-Asensio, E.; Piazza, G.; Delfino, F.; Giribone, P.G. (2020). Electricity *Spot* Prices Forecasting for MIBEL by using Deep Learning: a comparison between NAR, NARX and LSTM networks, in: 2020 IEEE International Conference on Environment and Electrical Engineering and 2020 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I CPS Europe). Presented at the 2020 IEEE International Conference on Environment and Electrical Engineering and 2020 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I CPS Europe), 1–6.
<https://doi.org/10.1109/EEEIC/ICPSEurope49358.2020.9160587>
- Steinert, R.; Ziel, F. (2019). Short- to mid-term day-ahead electricity price forecasting using futures. *The Energy Journal*, 40, 105–127.
doi: 10.5547/01956574.40.1.rste
- Trull, O.; García-Díaz, J.C.; Troncoso, A. (2020). Stability of multiple seasonal holt-winters models applied to hourly electricity demand in Spain. *Applied Sciences (Switzerland)*, 10, 2630.
<https://doi.org/10.3390/app10072630>
- Vahviläinen, I.; Pyykkönen, T. (2005). Stochastic factor model for electricity *spot* price – the case of the Nordic market. *Energy Economics*, 27(2), 351–367.
doi: 10.1016/j.eneco.2005.01.002
- Weron, R. (2007). Modeling and forecasting electricity loads and prices: A statistical approach. *The Wiley Finance Series*. 403
<https://books.google.pt/books?id=cXcWdMgovvoC>. Acedido a 11 maio 2021
- Weron, R. (2014). Electricity price forecasting: A review of the state-of-the-art with a look into the future. *International Journal of Forecasting* 30, 1030–1081.
<https://doi.org/10.1016/j.ijforecast.2014.08.008>
- Yan, X.; Chowdhury, N.A. (2013). Mid-term electricity market clearing price forecasting: A hybrid LSSVM and ARMAX approach. *International Journal of Electrical Power & Energy Systems* 53, 20–26.
<https://doi.org/10.1016/j.ijepes.2013.04.006>
- Ziel, F.; Steinert, R. (2018). Probabilistic mid- and long-term electricity price forecasting. *Renewable and Sustainable Energy Reviews*, 94, 251–266.
<https://doi.org/10.1016/j.rser.2018.05.038>

Websites:


- [1] <https://www.dgeg.gov.pt/pt/areas-setoriais/energia/eficiencia-energetica/cogeracao/>
Acedido a 2 abril 2021.
- [2] <https://www.edp.pt/empresas/empresas-com-energia/energia-solar-fotovoltaica-ou-termica/>
Acedido a 2 abril 2021.
- [3] <https://www.dgeg.gov.pt/pt/areas-setoriais/energia/energia-eletrica/producao-de-energia-eletrica/producao-em-regime-especial-renovavel-pre/enquadramento-legal/>
Acedido a 2 abril 2021.
- [4] <https://www.portugalenergia.pt/agentes/>
Acedido a 14 abril 2021.

- [5] <https://tarifasgasluz.com/distribuidoras>
Acedido a 13 maio 2021.
- [6] <https://www.erse.pt/atividade/regulacao/tarifas-e-precos-eletricidade/>
Acedido a 14 abril 2021.
- [7] <https://www.omie.es/es/mercado-de-electricidad>
Acedido a 14 abril 2021.
- [8] https://www.mercado.ren.pt/PT/Electr/InfoMercado/PressReleases/BibInfAnual/MercadoEletridadeSinteseAnual2017_202104.pdf
Acedido a 11 maio 2021.
- [9] <https://apambiente.pt/index.php?ref=17&subref=295&sub2ref=549&sub3ref=844>
Acedido a 14 abril 2021.
- [10] <https://www.iea.org/reports/covid-19-impact-on-electricity>
Acedido a 14 abril 2021.
- [11] <https://www.europarl.europa.eu/factsheets/pt/sheet/45/mercado-interno-da-energia>
Acedido a 14 abril 2021.
- [12] https://ec.europa.eu/energy/topics/renewable-energy_en
Acedido a 14 abril 2021.
- [13] <https://www.consilium.europa.eu/pt/press/press-releases/2018/12/04/energy-efficiency-renewables-governance-of-the-energy-union-council-signs-off-on-3-major-clean-energy-files/>
Acedido a 14 abril 2021.
- [14] <https://www.iea.org/reports/global-ev-outlook-2020#prospects-for-electrification-in-transport-in-the-coming-decade>
Acedido a 14 abril 2021.
- [15] <https://operdata.com.br/blog/coeficientes-de-correlacao/>
Acedido a 12 novembro 2020.


Anexos

ANEXO I. Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados e preços futuros na fase de teste. Cenário pré-pandemia


Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados da RNA M+1 e preços futuros M+1




Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados da RNA M+2 e preços futuros M+2




Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados da RNA M+3 e preços futuros M+3




Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados da RNA M+4 e preços futuros M+4



Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados da RNA M+5 e preços futuros M+5




Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados da RNA M+6 e preços futuros M+6




ANEXO II. Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados e preços futuros na fase de teste. Cenário pandemia


Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados da RNA M+1 e preços futuros M+1




Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados da RNA M+2 e preços futuros M+2




Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados da RNA M+3 e preços futuros M+3



Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados da RNA M+4 e preços futuros M+4



Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados da RNA M+5 e preços futuros M+5



Média mensal dos preços *spot* reais, média mensal dos preços *spot* estimados da RNA M+6 e preços futuros M+6

